

离散小波变换与注意力协同的陨石坑检测网络^{*}穆京畅 陈思琪 顾天昊
(青岛大学自动化学院 青岛 266000)

摘要: 复杂场景陨石坑的高精度检测在深空探测和行星科学领域中具有重要价值。本文针对沟壑区域内和边缘退化陨石坑的检测精度瓶颈,提出离散小波变换与交叉注意力协同的 HCF-YOLO 陨石坑检测网络。设计了小波频域保留下采样模块,缓解边缘退化陨石坑结构特征的衰退,提升其与背景的区分度,降低漏检率。其次,提出浅层引导的交叉注意力融合模块,以浅层陨石坑结构细节生成权重,定向约束与高层语义的跨尺度融合,抑制沟壑纹理噪声干扰并避免清晰大陨石坑的语义特征对结构特征的覆盖,降低背景噪声和特征混淆引发的误检。两模块协同强化复杂场景下的检测鲁棒性。最终,在 MDCC 数据集上开展系统对比与消融实验。与最新方法相比,真阳性(TP)检测数提升133个,召回率提升5%,精确率提升2%。

关键词: 陨石坑检测;离散小波变换;交叉注意力机制;特征融合;目标识别

中图分类号: TP391.41;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 120.10

Crater detection network with synergistic integration of discrete wavelet transform and attention mechanisms

Mu Jingchang Chen Siqi Gu Tianhao
(School of Automation, Qingdao University, Qingdao 266000, China)

Abstract: The capacity to detect craters in complex scenes is of paramount importance for the fields of deep space exploration and planetary science. In order to address the accuracy bottleneck in detecting degraded craters within rille regions and at crater margins, this paper proposes the HCF-YOLO crater detection network, which synergistically integrates discrete wavelet transform and cross-attention. The wavelet-domain preserved downsampling module is designed to mitigate the decay of structural features in degraded crater edges. This enhancement of distinguishability from the background is accompanied by a reduction in false negative rates. Secondly, a guided cross-attention fusion module is introduced. The generation of weights from shallow-level crater structural details is achieved in order to directionally constrain cross-scale fusion with high-level semantics. The suppression of rille texture noise interference is of particular significance in this context, as it prevents clear, large craters' semantic features from masking structural features. This, in turn, serves to reduce false positives caused by background noise and feature confusion. The two modules have been shown to enhance detection robustness in complex scenes in a synergistic manner. Finally, systematic comparisons and ablation experiments are conducted on the MDCC dataset. In comparison with state-of-the-art methods, true positive (TP) detections increase by 133, recall improves by 5%, and precision rises by 2%.

Keywords: crater detection;discrete wavelet transform;cross-attention mechanism;feature fusion;object recognition

0 引言

陨石坑检测在深空探测工程与行星科学领域中至关重要,支撑着陆点及基于视觉的地形相对导航中关键导航陆

标的选择,为行星年龄估算、地质信息推断等提供重要数据支持^[1-3]。早期陨石坑检测主要依赖专家手工标注,但该方法难以满足实时任务需求,且不同专家组之间的标注数量差异可高达45%^[4]。随着遥感技术的发展,高分辨率图像

收稿日期:2025-09-29

* 基金项目:国家自然科学基金(62403264)、中国博士后科学基金(2024M761556)、青岛市自然科学基金(24-4-4-zrjj-94-jcb)、山东省博士后创新项目(SDCX-ZG-202400312)、青岛市博士后应用研究项目(QDBSH20240102029)、青岛大学系统科学联合研究计划项目(XT2024202)资助

的数量迅速增长,人工标注已无法应对实际需求。因此,自动陨石坑检测算法(crater detection algorithm,CDA)逐渐成为研究重点。

在CDA研究中,传统的图像处理技术得到广泛应用,包括边缘检测、霍夫变换、分水岭算法、阈值分割或其组合方法等^[5]。此类无监督技术需预先设计检测规则,高度依赖算法设计,需大量人为干预以应对复杂背景带来的挑战。随后,自适应增强(adaptive boosting, AdaBoost)、随机森林(random forest, RF)、遗传算法(genetic algorithm, GA)与支持向量机(support vector machine, SVM)及其变体等有监督技术被引入陨石坑检测^[6]。此类技术能够在训练数据中学习规则,但缺乏自动提取特征的能力。检测精度受手工设计的陨石坑边缘和轮廓等代表性特征的质量影响^[7-8],存在对复杂形态陨石坑的检测瓶颈。综上所述,传统CDA在陨石坑检测的自动化方面取得了显著进展,但受限于严重依赖先验规则和特征代表性的缺陷,在大规模数据集和复杂场景下的检测可靠性仍存在挑战。

近年来,深度学习方法因自动完成特征提取和充分利用训练数据的能力受到重视,以端到端完成分类和定位的目标识别CDA为主,在大规模检测中取得显著进展^[9-11]。伴随陨石坑图像分辨率的提升,研究者提出了诸多针对小陨石坑检测的方案:设计特殊标签分配策略以平衡尺度差异;采用高分辨率特征金字塔与自注意力机制以提升特征提取效率^[12];借助超分辨率增强特征表征;改进检测头结构;运用数据增强方法等^[13]。

然而,现有目标识别CDA对边缘退化陨石坑和沟壑区域等复杂场景陨石坑的检测精度仍较差。目前多数目标识别CDA通过堆叠优化后的特征提取模块与下采样模块以提升多尺度特征提取能力,缺乏边缘纹理等结构特征的针对性优化。此外,利用类特征金字塔与跳跃连接等特征融合方法容易引起低区分度特征的混淆、跨尺度特征覆盖或背景噪声干扰,导致模型难以准确识别沟壑区域或密集小陨石坑群中的陨石坑特征^[14-15]。

本研究提出了HCF-YOLO陨石坑检测网络,旨在解决边缘退化陨石坑检测精度低以及沟壑区域等复杂场景中陨石坑检测精度低的问题。首先,本文针对退化陨石坑边缘纹理表征弱的缺陷,设计了小波频域保留下采样模块(wavelet-domain preserved downsampling module, WDPD)。模块引入离散小波变换思想,从频域处理陨石坑特征,针对性缓解边缘纹理等高频信息在下采样过程中的衰退,提升弱边缘特征的清晰度和可见性。其次,围绕跨尺度陨石坑特征之间的覆盖和沟壑特征干扰问题,本文提出了浅层特征引导的交叉注意力特征融合模块(guided cross-attention fusion, GCAFusion),协同利用WDPD优化后的清晰陨石坑结构特征增强跨尺度特征交互,提升背景噪声与陨石坑特征之间的可区分度并避免高语义特征对高结构特征的信息覆盖。

1 相关工作

1.1 目标识别CDA

现有的目标识别CDA主要围绕需先生成候选区域再进行检测的双阶段检测框架^[16-17]与能够直接输出检测结果的单阶段检测框架^[18-20]展开。围绕这两类框架,已有研究针对小目标与退化边缘的挑战提出了多种改进方法:Yang等^[21]提出的HRFPNet设计了标签分配算法和高分辨率特征金字塔网络应对陨石坑尺度失衡;Zhu等^[22]使用领域自适应进行形状不规则陨石坑的检测;Mu等^[23]构建了YOLO-crater,通过改进检测头实现陨石坑中心和半径的检测;Zhuo等^[6]构建自适应非极大值抑制模块优化重叠陨石坑检测;Nan等^[24]引入聚合分支路提升小陨石坑特征表征;Chatterjee等^[25]采用自适应阈值点的方法增强训练集;La Grassa等^[26]加入残差密集块增强陨石坑特征提取能力以及多种其他方案^[27-28]。

尽管上述方法在不同方面取得了成效,但研究仍聚焦于单模块改良,对模块间的协同作用关注不足。这种局限性在复杂场景下易导致模型对不同形态和状态陨石坑的检测精度不均衡。此外,目前常用的特征融合方式多采用通道维度的拼接或空间维度的相加,这种方式容易引发强表征特征对弱表征特征的干扰甚至覆盖^[29-30]。针对这一问题,本文提出的方法采用具有清晰结构信息的浅层特征与语义信息丰富的深层特征计算交叉注意力矩阵,规避无筛选的特征融合问题,使结构特征能够作用于语义特征,从而在保证两者表征完整性的同时提升整体检测性能。

1.2 下采样与离散小波变换

下采样操作是模型在降低分辨率和扩展感受野方面的核心手段,广泛应用于各类视觉模型中。然而,池化操作通过舍弃像素来减小图像尺寸,可能会导致关键信息丢失;而步幅卷积则容易引发通道混叠问题。为缓解这些问题,已有研究提出如低通抑混叠^[31]、多尺度加权^[32]和引入全局交互^[27]等解决方案。然而,此类方法仍局限于“先降低分辨率再修复”的思路,难以从根源上避免细节退化。对于陨石坑特征,若在浅层网络中丧失细节,后续层几乎无法完全恢复。这一缺陷易导致边缘退化的陨石坑特征表征更加薄弱,甚至被模型误判为噪声,进而造成更多干扰。而保持沟壑特征的清晰度,对于模型在准确区分噪声与真实陨石坑语义特征具有重要价值。

另一方面,部分研究者将图像视为信号,将下采样过程视作信息编码,通过滤波器在频域处理图像,并在图像分解、压缩、去噪和重建等任务中取得了显著成效^[33-34]。与之前工作不同,本文将哈尔小波变换与下采样操作融合,实现陨石坑特征不同方向的频域分解,再分别处理和融合包含不同信息的子带,旨在从源头避免“先丢失后补偿”的缺陷。该模块能够有效缓解退化陨石坑的边缘特征在下采样中的衰退,并在一定程度上强化陨石坑边缘特征与背景的可区分度和可见

性。同时,沟壑等噪声特征清晰度的提升有助于模型在特征融合阶段有选择性地规避,并使结构信息在融合中发挥主导作用,从而避免强表征特征对其他关键特征的掩盖。

2 HCF-YOLO

2.1 网络结构

本文提出的 HCF-YOLO 基于 YOLO11 架构展开。




图 1 面向复杂场景陨石坑检测网络 HCF-YOLO 结构

Fig. 1 Structure of the HCF-YOLO network for crater detection in complex scenes

HCF-YOLO 的全部下采样操作由 WDPD 模块完成,目的在于降低下采样操作引发的弱边缘陨石坑特征的结构信息损失和特征的衰退。在特征提取阶段,HCF-YOLO 交替使用 WDPD 模块、C3k2 模块,分别完成分辨率降低和不同分辨率特征提取,然后将 $1/32$ 原分辨率的特征传入 SPPF 和 C2PSA 模块提取大陨石坑的语义信息。同时,本文在颈部网络提出了 GCA Fusion 模块用于强化高级特征和低级特征的融合,提升目标特征的关键细节信息和语义信息的融合效果,同时抑制不同层级中 WDPD 模块在复杂区域内没有筛选的无效细节信息对目标特征的干扰。

2.2 WDPD 模块

传统下采样方法通过比较图像像素之间的关系,损失一部分低关联性、低重要性信息完成分辨率的降低^[35-36]。然而,此类方法在陨石坑检测任务中会引发陨石坑细节特征丢失和混叠伪影等问题,致使降低分辨率的过程中丢失弱边缘陨石坑的关键细节,引起网络漏检误检问题。本文设计构建了 WDPD 模块,利用哈尔小波基的离散小波变换

网络结构如图 1 所示,维持原始 YOLO11 模型的骨干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 的基本设计,保留 YOLO11 引入的 C3k2 模块与 C2PSA 模块。HCF-YOLO 在此基础上构建了 WDPD 模块替换原本的下采样模块,与 C3k2、SPPF 和 C2PSA 共同构成骨干网络。同时,本文在颈部网络引入 GCA Fusion 完成有指导性的融合不同层级特征。最终由检测头完成分类和定位。

在频域处理特征,减少下采样操作在降低分辨率过程中引起的弱边缘陨石坑的细节信息丢失。模块由哈尔小波特征频域分解 (Haar lossless decomposition, HaLD) 和通道筛选聚合 (channel selection and aggregation, CSA) 两阶段组成。哈尔小波频域特征分解将传入的特征分解为 4 种不同频带的子特征,将分辨率降低损失的细节信息编码入通道维度,在频域保留细节信息;然后将子特征进行通道整合筛选,留存关键性特征。通过分阶段操作使模块分别专注于通过频域处理空间特征和通道特征完成提取和整合,提高模型对任务目标特征的细节信息的提取和留存能力。原特征 (尺寸为 $C \times H \times W$) 经过该模块两阶段处理后之后下采样为 (尺寸为 $2C \times H/2 \times W/2$), 替代基本的步长卷积完成了下采样的任务。WDPD 结构如图 2 所示。

1) 哈尔小波特征频域分解

WDPD 第 1 阶段采用哈尔小波对特征进行二维离散小波变换,输入特征图分别通过不同顺序串联的两个一阶




图 2 WDPD 整体结构

Fig. 2 Structure of the WDPD overall architecture

一维的低通滤波器和高通滤波器进行多个频带的分解,快速降低特征图分辨率的同时得到不同频带的特征信息,完成空间特征的处理,通过频域处理保留原特征的细节信息,表现为特征分辨率减半和通道数的扩大。

如图 3 所示, ϕ_1 代表低通滤波器, ψ_1 代表高通滤波器,图像经过滤波器的处理后分解为低频分量(LL),水平(LH)、垂直(HL)、对角(HH)方向高频分量,尺寸均为原本的 1/4,但通道数扩展为原本的 4 倍。操作由本文设计的低通滤波器和高通滤波器完成。




图 3 哈尔小波频域分解

Fig. 3 Haar lossless decomposition

低通和高通滤波器是一组一维一阶哈尔小波变换如式(1)所示。

$$\begin{cases} \phi_j(x) = \frac{1}{\sqrt{2}}\phi_{j,0}(x) + \frac{1}{\sqrt{2}}\phi_{j,1}(x) \\ \psi_j(x) = \frac{1}{\sqrt{2}}\phi_{j,0}(x) - \frac{1}{\sqrt{2}}\phi_{j,1}(x) \end{cases} \quad (1)$$

其中, $\phi_j(x)$ 代表尺度函数,用以表示整体平均; $\psi_j(x)$ 代表小波函数用以表示局部差值。参数 j 代表阶数,表示哈尔小波的分解层数(或图像处理领域的尺度)。尺度函数族 $\phi_{j,k}(x)$ 和小波函数族 $\psi_{j,k}(x)$ 的定义如式(2)所示。

$$\begin{cases} \phi_{j,k}(x) = \sqrt{2^j}\phi_j(2^jx - k) \\ \psi_{j,k}(x) = \sqrt{2^j}\psi_j(2^jx - k) \end{cases} \quad (2)$$

其中,参数 $k = 0, \dots, 2^j - 1$, 表示平移参数,用以控制变换位置。此外, ϕ_0 和 ψ_0 如式(3)和(4)所示。

$$\phi_0(x) = \begin{cases} 1, & 0 \leq x < 1 \\ 0, & \text{其他} \end{cases} \quad (3)$$

$$\phi_0(x) = \begin{cases} 1, & 0 \leq x < 0.5 \\ -1, & 0.5 \leq x < 1 \\ 0, & \text{其他} \end{cases} \quad (4)$$

综上,一阶一维的哈尔小波变换如式(5)所示。

$$\begin{cases} \phi_1(x) = \phi_0(2x) + \phi_0(2x - 1) \\ \psi_1(x) = \phi_0(2x) - \phi_0(2x - 1) \end{cases} \quad (5)$$

其中, ϕ_1 代表低通滤波器; ψ_1 代表高通滤波器。

2) 通道筛选聚合

哈尔小波特征频域分解将分辨率降低引起的空间特征损失编码入通道维度的同时也保留了与目标无关的冗余细节信息。WDPD 设置了通道筛选聚合操作,结构如图 2 右侧框,计算过程如式(6)所示。

$$\mathbf{F}_i = \text{RELU}(\text{Bn}(\text{Conv}_{1 \times 1}(\text{Concat}(\mathbf{F}_{\text{HaLD}}^i)))) \quad (6)$$

其中, $\mathbf{F}_{\text{HaLD}}^i (i = 1, 2, 3, 4)$ 表示分解后的 4 个分量, $\mathbf{F}_i$ 由按顺序通道拼接、 1×1 卷积、批量归一化和 ReLU 激活函数组成。只专注于对通道操作,压缩和去除冗余信息(噪声、非目标边缘信息)的同时使通道匹配后续处理层,使网络取得更高的检测精度。

2.3 GCAFusion 模块

通道拼接是得到广泛应用的特征融合方式,但缺乏跨尺度信息交互,无法过滤噪声和冗余信息。为此,本文受 Transformer 使用的注意力机制捕获全局特征和长距离信息方式的启发,设计了一种跨尺度特征注意力引导融合模块,结构如图 4 所示。




图 4 交叉注意力融合模块 GCAFusion

Fig. 4 Cross-attention fusion module GCAFusion

GCAFusion 模块被设置在颈部网络不同位置,使用不同分辨率的低级特征计算对应的高级特征的相关性,生成交叉注意力矩阵,融合高维和低维的特征,增强特征的表达能力。其中, $\mathbf{F}_{\text{low}}^i \in \mathbf{R}^{H \times W \times C_i}$ 表示第 i 层低级特征, $\mathbf{F}_{\text{high}}^j \in \mathbf{R}^{H \times W \times C_j}$ 表示 Neck 第 j 层高级特征。首先,要对特

征进行通道对齐和特征投影,计算公式为:

$$\boldsymbol{Q} = \boldsymbol{W}_{1 \times 1} \langle \boldsymbol{\mathcal{F}}_{\text{low}}^i \rangle \tag{7}$$

其中, $\boldsymbol{W}_{1 \times 1}$ 为 1×1 卷积层、批量归一化层和 ReLU 激活函数的组合, $\boldsymbol{Q} \in \mathbf{R}^{H \times W \times C}$ 为生成的查询(Query)。同理计算 $\boldsymbol{K}, \boldsymbol{V}$:

$$\begin{cases} \boldsymbol{K} = \boldsymbol{W}_{3 \times 3}^1 \langle \boldsymbol{\mathcal{F}}_{\text{high}}^j \rangle \\ \boldsymbol{V} = \boldsymbol{W}_{3 \times 3}^2 \langle \boldsymbol{\mathcal{F}}_{\text{high}}^j \rangle \end{cases} \tag{8}$$

此时, $\boldsymbol{Q}, \boldsymbol{K}$ 和 $\boldsymbol{V}$ 形状为 $H \times W \times C(C_j)$ 。将 $\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}$ 展平为序列形式,重塑为 $\hat{\boldsymbol{Q}} \in \mathbf{R}^{\hat{H} \times \hat{W} \times \hat{C}}, \hat{\boldsymbol{K}} \in \mathbf{R}^{\hat{C} \times \hat{H} \times \hat{W}}$ 和 $\hat{\boldsymbol{V}} \in \mathbf{R}^{\hat{C} \times \hat{H} \times \hat{W}}$,通过计算 $\hat{\boldsymbol{K}}$ 和 $\hat{\boldsymbol{Q}}$ 的相似性矩阵,归一化为注意力权重 $\boldsymbol{A}$,注意力计算公式为:

$$\boldsymbol{O}_{\text{flat}} = \boldsymbol{A} \hat{\boldsymbol{V}}, \boldsymbol{O}_{\text{flat}} \in \mathbf{R}^{\hat{C} \times \hat{H} \times \hat{W}} \tag{9}$$

$$\boldsymbol{A} = \text{softmax}\left(\frac{\hat{\boldsymbol{K}} \hat{\boldsymbol{Q}}}{\sqrt{d}}\right), \boldsymbol{A} \in \mathbf{R}^{\hat{C} \times \hat{C}} \tag{10}$$

其中, $d = C_j$ 为缩放因子,用于缓解高维点积导致的梯度不稳定问题。将 $\boldsymbol{O}_{\text{flat}}$ 重塑后最终计算的输出为:

$$\boldsymbol{\mathcal{F}}_{\text{out}}^j = \text{reshape}(\boldsymbol{O}_{\text{flat}}) + \boldsymbol{\mathcal{F}}_{\text{high}}^i \tag{11}$$

3 数据及实验设置

3.1 数据集

为评估模型面向复杂场景陨石坑,尤其是弱边缘陨石坑的检测能力,本研究实验均在由 Yang 等^[21]提出的 MarsDayCD(MDCD)最新数据集进行,该数据集在火星全球范围内裁切出 500 张 729×729 pixels 的包含多地貌条件、多尺寸陨石坑红外成像(波长为 $12.57 \mu\text{m}$)图片,基础分辨率为 256 像素每度(pixels per degree, PPD),12 000 个标签。标签整体呈现显著的长尾分布特征,直径 <

50 pixels 的样本占比达到 75%,直径 > 200 pixels 的大型陨石坑仅占 1%,该数据集聚焦边缘退化陨石坑以及被遮挡、覆盖的陨石坑,包含有大量沟壑区域图像,同时剔除了截取造成的不完整陨石坑标签。

3.2 实验设置和评价指标

实验平台为 NVIDIA GeForce RTX 3090,实验所用 CUDA 版本为 11.7、Python3.8、Pytorch2.0.1 深度学习框架。按照 8:1:1 的比例随机划分图像。本文为保证对比的公平性,均未使用预训练权重开始训练,其他全部参数保持一致,具体的训练参数如表 1 所示。

表 1 训练参数设置
Table 1 Training parameter settings

参数	设置	参数	设置
训练周期	500	初始学习率	0.01
图片大小	640	结束学习率	0.000 1
批次大小	16	学习率动量	0.937
工作线程	8	优化器	SGD

本任务为单类别的目标识别任务,任务只会出现正类(目标)和负类(背景),选取真正例(TP)数量,计算精确度(precision, P)和召回率(recall, R)衡量模型的误检率和漏检率,采用 $\text{IoU} \geq 0.5$ 的指标 mAP@50 作为衡量网络可靠程度。

4 实验结果分析

4.1 对比实验

本文将 HCF-YOLO 与其他目标识别检测网络在 MDCD 的数据集的测试集上进行了对比,其对比结果如表 2 所示。

表 2 对比实验结果分析
Table 2 Comparison experiment results analysis

方法	TP 个数	$P/\%$	$R/\%$	mAP@50/%	GFLOPs
YOLO-Crater	2 103	78.05	73.2	—	26.9
YOLOLens	2 271	80.30	76.3	84.7	155.9
HRFPNet	2 392	82.30	80.2	—	97.8
Faster-RCNN	1 872	75.78	76.8	—	91.3
YOLOv5-samll	2 011	77.20	73.1	78.8	24.1
YOLOv8-small	2 117	79.90	72.8	80.4	28.6
PP-YOLOE+	2 132	79.30	75.0	81.7	18.8
RT-DETR-mobile	2 107	78.60	73.5	79.4	54.7
RT-DETR	2 171	79.60	75.0	82.8	134.8
YOLO11-small	2 203	79.10	73.2	83.3	17.6
HCF-YOLO(本文)	2 525	84.20	85.2	90.1	45.2

如表 2 所示,HCF-YOLO 与最新的双阶段陨石坑检测模型 HRFPNet 对比,精确率提高 2%,召回率提高 5%,TP 数量上升 133 个,GFLOPs 却下降了 52.6;与表现最好

但 GFLOPs 单阶段陨石坑检测模型相比,精确率提高 3.9%,召回率提升 9%,TP 数量上升 354 个。总体而言,HCF-YOLO 在真正例数量、精确度、召回率和 $F1$ 分数

4 项指标都取得了最优,这表示其具备更好的分辨能力。

同时, HCF-YOLO 只比部分轻量化的模型的 GFLOPs 略高,远低于其他复杂模型,这表明仅依靠更复杂的网络设计无法取得更好的成绩。HCF-YOLO 仅依靠小幅度计算复杂度的提升获得了最优异的检测能力,这归因于 WDPD 模块和 GCAFusion 模块的能力和协同配合。WDPD 最大程度地降低下采样操作造成的信息丢失,结合 GCAFusion 强大的指向性特征融合能力,在复杂特征中极大程度消除沟壑特征带来的影响。后者以小幅计算复杂度提升的代价,有效提升了网络对复杂场景陨石坑特征的捕捉和提取能力和跨尺度关键特征的留存以及细节信息和语义信息的融合能力,实现了复杂度与性能的合理平衡。图 5 为几种检测网络与 HCF-YOLO 的检测可视化对比图,置信度均设置为 0.25。

4.2 消融实验

为验证本文所设计模块发挥的作用,本文在基线网络基础上逐步增加模块进行训练和验证。使用精确度和召回率作为主要评价指标,TP 数量和 mAP50 作为次要评价指标。消融实验的结果如表 3 所示,网络在仅添加 WDPD 时,精确度提升了 2%,召回率提升了 10%。WDPD 能够最大程度保留细节信息的能力极大地提升了网络的检测能力。

本文通过在 WDPD 模块中使用 Daubechies (dbN)、Symlet(symN)以及 Coiflet(coifN)3 类小波探讨小波类型对模块的影响,结果如表 4 所示。量化结果表明在 WDPD 中采用小波提供的低频+高频分离的信息能够有效提升下采样效果,指标明显上升。然而当采取更高平滑性和支




图 5 不同模型与 HCF-YOLO 对比

Fig. 5 Comparison of different models with HCF-YOLO

表 3 消融实验对比分析

Table 3 Ablation experiment comparison analysis

Baseline	WDPD	GCAFusion	TP 数量	P / %	R / %	mAP50 / %
✓			2 292	81.3	76.8	83.3
✓	✓		2 311	83.2	83.6	87.8
✓		✓	2 494	82.4	84.6	88.6
✓	✓	✓	2 525	84.2	85.2	90.1

表 4 WDPD 小波实验对比分析

Table 4 Comparative analysis of WDPD wavelet experiments

类型	TP	P / %	R / %	mAP50 / %
Baseline	2 161	79.1	73.2	83.3
db2	2 271	82.9	82.6	86.3
db4	2 204	81.3	80.8	84.6
sym2	2 236	82.8	82.6	85.8
sym4	2 197	81.2	80.5	84.1
coif2	2 213	81.7	81.8	85.3
Haar	2 311	83.2	83.6	87.8

撑范围的小波时,指标却出现了小幅度下降,而哈尔小波始终保持最优指标。这归因于更高的平滑性会导致小波在微弱边缘处产生震荡,甚至混淆深层网络特征的抽象语义边界,从而干扰下采样结果。而哈尔小波能够最大程度还原局部微小差异,不引入额外噪声,协助 WDPD 提供无损的下采样结果。

此外,本文对不同小波变换的结果进行了可视化,采用不同小波对图像进行小波变换后得到高频子带图像,如图 6 所示。图 6 中哈尔小波子带中的结构信息得到最大程度的保留。虽然 dbN 与 symN 小波对高频信息的获取能力优于哈尔小波,但其中包含大量噪声。在 WDPD 模块进

行通道聚合时,包含噪声的子带通道数是低频子带通道数的 3 倍,这不可避免地降低了 WDPD 模块得到的特征下采样结果,进而对后续的特征融合造成无法挽回的影响。量化结果中替换小波后指标的下降也印证了这一点。




图 6 WDPD 不同小波变换效果高频子带效果

Fig. 6 Comparative analysis of WDPD wavelet experiments

其次,本文将同一阶段步长卷积(strided convolution, CBS)、平均池化(average pool)、最大池化(max pool)与 WDPD 对传入特征下采样后的结果进行了可视化,结果如图 7 所示。




图 7 同一阶段传统下采样与 WDPD 下采样对比

Fig. 7 Comparison between traditional downsampling and WDPD downsampling in the same stage

可以明显地看出 WDPD 相比于其他 3 种下采样手段保留了更多边缘细节。此外,不同像素特征图中,WDPD 始终保持比 CBS 更优越的性能,对关键特征的细节信息保留能力更强,对比结果如图 8 所示。

图 8 展示了不同阶段两者的差别,其中,图 8(a)为下




图 8 不同阶段 CBS 与 WDPD 对比

Fig. 8 Comparison between CBS and WDPD in different stages

采样两次两种方法的对比,图 8(b)为下采样 4 次两种方法的对比。很显然,即使网络深度增加和采样次数逐步增加,WDPD 对特征的处理也始终保持优势。

此外,HCF-YOLO 在仅使用 GCAFusion 时精确度和召回率分别上升了 1.1%和 11.4%。最后当两种模块同时使用时,所有评价指标达到最高,证明了模块组合使用对任务目标的识别效率达到了最高。同时,本文将两个模块协同作用时 GCAFusion 模块的注意力权重掩膜和特征热力图进行了可视化,分别如图 9 和 10 所示。




图 9 不同阶段 GCAFusion 注意力权重掩膜

Fig. 9 Attention weight masks of GCAFusion at different stages




图 10 添加不同模块对特征提取热力图

Fig. 10 Adding different modules for feature extraction heatmap

图 9 为不同阶段 GCAFusion 的注意力权重在原图的掩膜,从左到右按照特征在模型中的传递顺序排列。可以得出,在不同阶段 GCAFusion 接受低维特征的清晰结构信息指导,按照不同侧重将高维特征和低维特征进行聚合。第 1 阶段,GCAFusion 专注于小型和中型陨石坑;第 2 阶段专注于陨石坑边缘和小型陨石坑,避免退化陨石坑被覆盖;第 3 阶段再次专注于中型陨石坑,降低沟壑、隆起等无

关噪声造成的影响;最后阶段专注于大型陨石坑和边缘清晰的陨石坑。

图10是在基线网络的基础上添加不同模块后特征提取的热力图,颜色越红表示网络对该处特征的识别和提取越明显。其中,图10(a)表示未添加任何模块的检测网络,小陨石坑的特征表示稀疏,大陨石坑的特征聚合较弱;图10(b)为仅添加WDPD模块,可以得出WDPD可以让网络最大限度地保留小目标和边缘复杂情况的细节特征,但也会因此在一定程度上使得重要特征的聚合结果更“分散”;图10(c)为仅添加GCAFusion模块,极大程度地将特征进行了聚合,确保不同阶段提取的特征能够在输出给检测头时保留下来;图10(d)为两个模块搭配使用时,热力图显示网络对不同尺度的特征提取和聚合能力达到了平衡,取得了最理想的情况。

5 结 论

针对前景和背景区别度低及背景复杂条件下小陨石坑和弱边缘陨石坑识别率低的问题,本文提出了一种离散小波变换低损下采样的跨尺度引导性聚合的陨石坑检测网络HCF-YOLO。设计小波频域保留下采样模块WDPD用于骨干网络,降低下采样操作带来的细节信息丢失;提出GCAFusion进行带有指向性的特征融合,克服单纯通道拼接方案受复杂背景干扰所产生的特征提取冲突,并降低噪声造成的影响,降低WDPD保留的噪声和沟壑地区的高频特征对于目标特征的干扰。在MDCD数据集上进行的实验研究结果表明,模块取得了理想的效果,并且与其他经典和先进的目标识别方法相比,本文提出的方法针对小陨石坑和弱边缘陨石坑的检测精度有着显著提升。未来研究将围绕在保障识别精度的同时削减模型参数量、降低计算复杂度这一目标展开,以满足对推理速度具有更高要求的场景和任务。

参考文献

- [1] MAASS B, WOICKE S, OLIVEIRA W M, et al. Crater navigation system for autonomous precision landing on the moon[J]. *Journal of Guidance, Control, and Dynamics*, 2020, 43(11): 1-18.
- [2] LIU J J, REN X, YAN W, et al. Descent trajectory reconstruction and landing site positioning of Chang'E-4 on the lunar farside[J]. *Nature communications*, 2019, 10(1): 4229.
- [3] 张成渝, 梁潇, 吴奋陟, 等. 小行星探测下降着陆段光学导航技术发展综述[J]. *红外与激光工程*, 2020, 49(5): 113-124.
- [4] ZHANG C Y, LIANG X, WU F Z, et al. Overview of optical navigation for asteroid exploration descent and landing[J]. *Infrared and Laser Engineering*, 2020, 49(5): 113-124.
- [5] YANG S J, CAI Z C. Progressive domain adaptive

- network for crater detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-12.
- [6] CHEN D, HU F, ZHANG L Q, et al. Impact crater recognition methods: A review[J]. *Science China Earth Sciences*, 2024, 67(6): 1719-1742.
- [7] ZHUO M, WANG Y R, ZHANG X R, et al. High-accuracy crater detection for complex planetary surfaces[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 1-14.
- [8] SILBURT A, ALI-DIB M, ZHU C C, et al. Lunar crater identification via deep learning[J]. *Icarus*, 2019, 317: 27-38.
- [9] LI W W, ZHOU B, HSU C Y, et al. Recognizing terrain features on terrestrial surface using a deep learning model: An example with crater detection[C]//1st Workshop on Artificial Intelligence and Deep Learning for Geographic Knowledge Discovery, 2017: 1-4.
- [10] MAO Y Q, YUAN R G, LI W, et al. Coupling complementary strategy to U-Net based convolution neural network for detecting lunar impact craters[J]. *Remote Sensing*, 2022, 14(3): 661.
- [11] 吴葛, 朱宇凡, 贾泽宁. 改进YOLO11的PCB表面缺陷检测方法[J]. *电子测量技术*, 2025, 48(14): 136-145.
- [12] WU G, ZHU Y F, JIA Z N. Improved PCB surface defect detection method based on YOLO11[J]. *Electronic Measurement Technology*, 2025, 48(14): 136-145.
- [13] DELATTE D M, CRITES S T, GUTTENBERG N, et al. Segmentation convolutional neural networks for automatic crater detection on mars[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(8): 2944-2957.
- [14] 李明光, 陶重舜. 基于Transformer的特征频率解耦融合三维目标检测方法[J]. *仪器仪表学报*, 2025, 46(7): 345-357.
- [15] LI M G, TAO C B. Feature frequency decoupling and fusion for 3D object detection with Transformer[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(7): 345-357.
- [16] CHAINI C, JHA V K. A review on deep learning-based automated lunar crater detection[J]. *Earth Science Informatics*, 2024, 17(5): 3863-3898.
- [17] STERGIOU A, POPPE R, KALLIATAKIS G. Refining activation downsampling with SoftPool[C]//2021 IEEE/CVF International Conference on Computer Vision, 2021: 10337-10346.
- [18] JANG D H, CHU S, KIM J, et al. Pooling revisited: Your receptive field is suboptimal[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 539-548.
- [19] WANG S, FAN Z Z, LI ZH M, et al. An effective

- lunar crater recognition algorithm based on convolutional neural network[J]. *Remote Sensing*, 2020, 12(17): 2694.
- [17] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [18] ALI-DIB M, MENOUE K, JACKSON A P, et al. Automated crater shape retrieval using weakly-supervised deep learning [J]. *Icarus*, 2020, 345: 113749.
- [19] 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, 2016: 779-788.
- [20] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [21] YANG S J, CAI Z C. High-resolution feature pyramid network for automatic crater detection on mars[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-12.
- [22] ZHU J H, LIANG J R, TIAN X L. Lunar impact crater detection based on YOLO v7 using multi-source data [C]//2023 IEEE International Conference on Control, Electronics and Computer Technology (ICCECT), 2023: 901-905.
- [23] MU L L, XIAN L N, LI L H, et al. YOLO-crater model for small crater detection[J]. *Remote Sensing*, 2023, 15(20): 5040.
- [24] NAN J, WANG Y X, DI K C, et al. YOLOv8-LCNET: An improved YOLOv8 automatic crater detection algorithm and application in the Chang'e-6 landing area[J]. *Sensors*, 2025, 25(1): 243.
- [25] CHATTERJEE S, CHAKRABORTY S, NATH A, et al. Near-real-time detection of craters: A YOLO v5 based approach[C]//2023 International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing, 2023: 1-4.
- [26] LA GRASSA R, CREMONESE G, GALLO I, et al. YOLOLens: A deep learning model based on super-resolution to enhance the crater detection of the planetary surfaces[J]. *Remote Sensing*, 2023, 15(5): 1171.
- [27] GUO Y, WU H, YANG S J, et al. Crater-DETR: A novel transformer network for crater detection based on dense supervision and multiscale fusion[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1-12.
- [28] DAI Y Q, XUE C B, DU A A. Boosting crater detection via ViT-based feature fusion from Near-IR images and DEMs[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 1-5.
- [29] 朱朋,邓蕾,汤宝平,等.数字孪生驱动小波注意力迁移网络的齿轮箱故障诊断方法[J]. *仪器仪表学报*, 2025, 46(10): 86-95.
- ZHU P, DENG L, TANG B P, et al. Digital twin driven wavelet attention transfer network for gearbox fault diagnosis [J]. *Chinese Journal of Scientific Instrument*, 2025, 46(10): 86-95.
- [30] 陈晓雷,温润玉,杨富龙,等.基于空频特征融合的双流晶圆缺陷分类网络[J]. *电子测量与仪器学报*, 2024, 38(8): 56-67.
- CHEN X L, WEN R Y, YANG F L, et al. Dual-stream wafer defect classification network based on spatial and frequency domains feature fusion [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(8): 56-67.
- [31] ZHANG R. Making convolutional networks shift-invariant again [C]//International Conference on Machine Learning, 2019: 7324-7334.
- [32] DU S H F, YANG Y S, YUAN H B, et al. Application of deep learning for real-time detection, localization, and counting of the malignant invasive weed *Solanum rostratum* Dunal[J]. *Frontiers in Plant Science*, 2025, 15: 1486929.
- [33] LI Q, ZHANG W, LU W X, et al. Multi-branch mutual-guiding learning for infrared small target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 1-10.
- [34] ZHANG L W, ZHOU Z D, XU Y F, et al. Classification of imagined speech EEG signals with DWT and SVM[J]. *Instrumentation*, 2022, 9(2): 56-63.
- [35] LI T, GANG Y J, LI S M, et al. A small underwater object detection model with enhanced feature extraction and fusion[J]. *Scientific Reports*, 2025, 15(1): 2396.
- [36] LI S, JIANG Q B, XU Y D, et al. Digital twin-assisted interpretable transfer learning: A novel wavelet-based framework for intelligent fault diagnostics from simulated domain to real industrial domain[J]. *Advanced Engineering Informatics*, 2024, 62: 102681.

作者简介

穆京畅,硕士研究生,主要研究方向为机器学习、目标识别以及深空探测。

E-mail: mujingchang@qdu.edu.cn

陈思琪,硕士研究生,主要研究方向为机器学习、小样本语义分割以及深空探测。

E-mail: chensiqi@qdu.edu.cn

顾天昊(通信作者),博士,副教授,主要研究方向为模式识别、机器学习、视觉导航以及深空探测。

E-mail: gutianhao@qdu.edu.cn