

doi: 10.3969/j.issn.1000-8349.2014.01.01

基于 YOLOv5 的类地行星陨石坑智能检测与分类

袁煦童^{1,2}, 李希之¹

(1. 中国科学院 上海天文台, 上海 200030; 2. 中国科学院大学, 北京 100049)

摘要: 在深空探测着陆任务中, 探测器将通过传感器获取的天体表面实时图像进行着陆点选取, 这些图像包含了类地行星表面复杂的地貌特征。陨石坑作为显著的地貌特征之一, 既可作为探测器的导航地标, 又需在降落过程中进行避让。然而, 陨石坑在尺度、光照和数量上的多样性使得其实时检测与识别面临巨大挑战。传统图像处理技术耗时长且易出现漏检或错检, 难以满足实时快速检测的需求。近年来, 人工智能技术在目标检测领域取得了显著进展, 涌现出多种高效算法。本研究基于 YOLOv5 提出了一种改进的陨石坑智能检测模型, 并构建了专用的陨石坑数据集用于训练。为适应不同尺度陨石坑的检测需求, 研究改进了模型网络结构, 增加了小尺度特征提取模块并优化了特征融合方式。实验结果表明, 改进后的模型在陨石坑数据集上的平均精度 (mAP@50) 从 79.2% 提升到了 81.2%, 相当于增加约 100 张训练图像后近 2% 的提升, 提高了对小目标陨石坑的识别率, 同时具备陨石坑分类功能。在训练集数据量较小的小样本检测任务中具有较大应用价值。模型与当前主流开放世界目标检测通用大模型 DINO-X 对比, 改进模型在陨石坑识别准确率上具有显著优势, 且对不同光照条件的识别具有较好的鲁棒性。本研究为陨石坑实时检测及相关任务提供了重要参考, 展现了其在深空探测任务中的潜在应用价值。

关 键 词: 深空探测; 类地行星; 陨石坑; 目标检测; YOLOv5

中图分类号: P1 文献标识码: A

1 引言

类地天体表面普遍分布着陨石坑, 直径从亚千米级到数百公里不等, 且形态各异^[1], 这些陨石坑的形成机制主要与天体表面的撞击事件有关, 其分布和形态特征为研究天体表面的地质演化提供了重要线索。深空探测任务中, 探测器相机获取的遥感图像包含了陨石坑的丰

收稿日期: 2025-02-01; 修回日期: 2025-02-01

资助项目: 国家自然科学基金面上项目 (12273092); 上海市 2022 年度“科技创新行动计划”港澳台科技合作项目 (22590760900)

通讯作者: 李希之, lixizhi@shao.ac.cn

富信息，如数量、分布特征和形态结构等。这些信息在地质学上具有重要意义，不仅可以用于研究陨石坑形成的机理和动力学，还能帮助我们了解天体表面地貌的演化历史，评估地质单元的相对地质年龄^[2]，推算陨石坑撞击通量^[3]，并促进了大量行星地质问题的研究，如自然降解过程、地质区域性差异、地下挥发物质的分布等。

例如，王丹等人^[4]利用月球卫星影像数据和陨石坑相关信息，发现了月表存在与地表类似的冻融地貌，这对探讨月球是否存在水冰，以及进一步开展月球形成与演化等研究具有重要意义。通过识别月表陨石坑并统计其数量和大小，应用产率函数和年代函数可以估算区域地质年龄。这种定年方法也可以推广到太阳系其他类地行星上。此外，对撞击通量的研究有助于我们了解陨石的撞击过程，并且陨石的撞击会将少量物质溅射到其他天体上，实现星际物质的转移，这对生命在宇宙中的传播具有重要意义^[5]。

从地质学角度分析，识别陨石坑的形状以及大小可以为类地天体表面圆形坑和环形山构造的陨石轰击成因假说提供依据。研究陨石坑的分布形态等可以推断陨石撞击方向、速度、质量以及烧蚀破裂情况^[6]。对陨石坑进行合理的分类有助于了解成坑原因，进而比较得出撞击作用力与破坏作用力对成坑机制的影响^[7]。识别火星表面可能发生松弛或掩埋的撞击盆地，对理解火星早期撞击历史和撞击通量至关重要，同时还能揭示这些撞击事件是如何改造火星地壳结构并影响早期气候环境。根据撞击通量随时间变化的函数关系获得原始陨石坑和退化陨石坑的大小频率的概率密度分布，进而揭示撞击盆地的地表改造历史差异与这两类陨石坑的大小频率的概率密度差异之间的关系。通过对火星大型撞击盆地年龄和退化状态的系统研究，可以为行星热演化历史提供重要制约，推动对火星关键地质时期的认知。^[8]

除地质学意义外，在深空探测工程中，陨石坑作为水星、火星、月球及其他卫星等天体表面最显著的地形特征，具有双重作用：一方面，它们是探测器安全着陆所需避开的障碍；另一方面，其独特形态可作为地面标志物，用于探测器定位算法的特征跟踪^[9]。在此过程中，陨石坑的实时自动识别至关重要。部分陨石坑轮廓清晰，可通过视觉技术作为姿态确定中的跟踪目标和着陆场搜索中的障碍物目标，为探测器自主着陆提供导航参照^[10]。例如，Maass 等人^[11]提出了一种基于陨石坑检测与匹配的自适应导航系统，利用图像分割技术对内部阴影和明亮相邻区域进行拟合来确定陨石坑形状，实现了着陆器的定位、定姿与导航。然而，该方法对山脉、山脊等非陨石坑地形的误检限制了其精度。此外，通过识别陨石坑，还可以预先收集天体表面的几何拓扑信息，为未来基础设施和基站建设提供参考^[12]。

然而，陨石坑数量庞大且形态多样，其分类与识别面临挑战。传统方法依赖光学影像中的光照对比和纹理特征，但受限于太阳高度角和人为定义规则，常将类地行星表面的近圆形山丘、沙丘等地貌误识别为陨石坑^[1]。此外，由于影像分辨率低、陨石坑边缘模糊等因素，传统方法难以实现精确识别，且由于信息传递的延迟，无法满足探测器导航的实时要求。近年来，基于神经网络的目标检测算法逐渐成为主流，其通过减少目标尺度和光照变化的影响，显著提高了识别精度和实时性。

目前，神经网络图像识别技术在科学和工程领域得到广泛应用。在天文领域，基于神经网络的陨石坑识别方法已取得显著进展。例如，Downes 等人^[13]基于卷积神经网络提出的LunaNet 模型能够检测月表陨石坑并匹配陨石坑数据库来修正导航误差，但对较大陨石坑的

漏检问题仍未解决。Hu 等人^[14] 利用 YOLOv4 改进了传统图像处理技术在障碍物识别中的漏检现象, 但其模型在处理小陨石坑时仍存在局限性。Tewari 等人^[15] 基于 Mask R-CNN 网络开发的月表陨石坑检测模型虽能识别数据库中未标记的新坑, 但其双阶段检测框架导致检测速度较慢。以上几种模型在检测速度、精度和分类功能方面仍存在不足, 难以满足深空探测任务中对陨石坑实时检测与分类的要求, 因此选取更加适合实时检测的模型并构建陨石坑分类数据集至关重要。

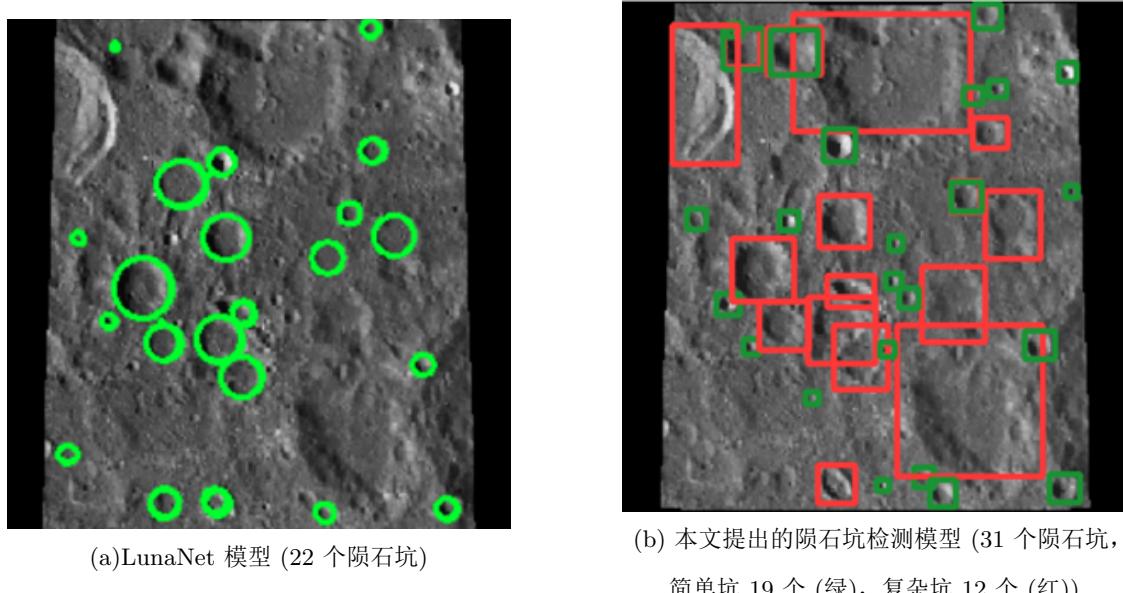


图 1 LunaNet 模型和本文提出的陨石坑检测模型在月表遥感图像的识别结果对比

本文基于深空探测光学遥感数据构建了陨石坑识别与分类数据集, 提出了一种改进的 YOLOv5 目标检测模型。该模型针对多尺度识别进行了改进, 提高了模型对不同尺度陨石坑检测的鲁棒性和准确率, 且相比其他模型具有较高的检测速度, 为天体表面陨石坑的精确识别与分类提供了新的解决方案。第 2 章论述了模型框架与网络改进方法; 第 3 章详细介绍了数据集的制作、模型评估指标及实验结果分析; 第 4 章总结了研究的成果及创新性, 并对未来工作进行了展望。

2 方法

2.1 YOLOv5 的网络结构与模型框架

YOLOv5^①是 YOLO 系列中较为成功且广泛应用的算法, 由 Glenn-Jocher 于 2020 年提出。该算法采用路径融合的特征金字塔网络进行特征提取与融合, 能够实现高效的目标识别

^①<https://github.com/ultralytics/yolov5>

与分类，具有速度快、准确度高的特点，已被广泛应用于自动驾驶、工业检测等领域。鉴于YOLOv5在实时检测方面的显著优势，我们选择其作为基础网络，用于陨石坑的识别与分类任务。

YOLOv5的网络结构如图2所示，主要由三个部分组成：主干网络(Backbone)、颈部网络(Neck)和头部网络(Head)。这三部分分别承担不同的功能，以下对各部分的功能进行详细说明。

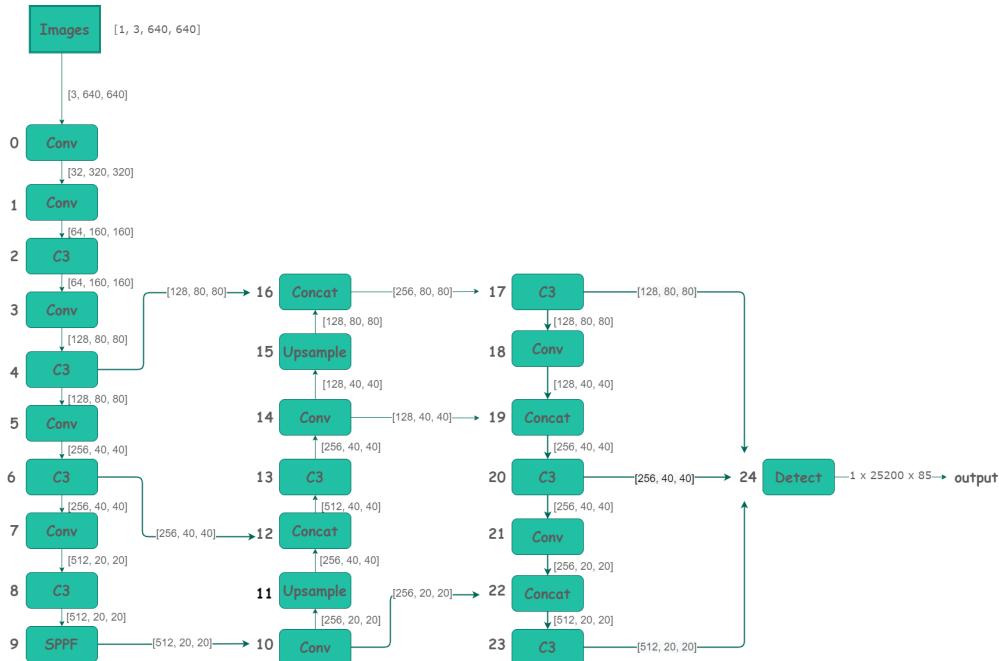


图2 YOLOv5网络结构示意图^①

主干网络：主干网络负责特征提取。输入图像首先通过自适应图像缩放调整为640*640像素，随后经过多个卷积一批归一化—激活函数模块(Conv-BN-Silu, CBS)进行下采样，生成三种尺度的特征图(80×80 、 40×40 和 20×20 像素)，本研究定义为C3、C4和C5。主干网络的输出经过空间金字塔快速池化模块(Spatial Pyramid Pooling-Fast, SPPF)，通过多尺度池化操作融合不同分辨率的特征，进一步增强特征提取能力。

颈部网络：颈部网络采用路径融合网络—特征金字塔网络(Path Aggregation Network-Feature Pyramid Network, PAN-FPN)结构，对主干网络生成的C3、C4和C5特征信息进行融合，生成对应尺度的特征图(80×80 、 40×40 和 20×20 像素)，本研究定义为P3、P4和P5。通过聚合不同尺度的特征信息，颈部网络能够充分利用每一层特征图的信息，从而提升检测精度。

头部网络：头部网络通过卷积操作将多尺度特征张量转换为包含检测框位置、目标置信

^①https://start.oneflow.org/onflow-yolo-doc/tutorials/01_chapter/yolov5_network_structure_analysis.html

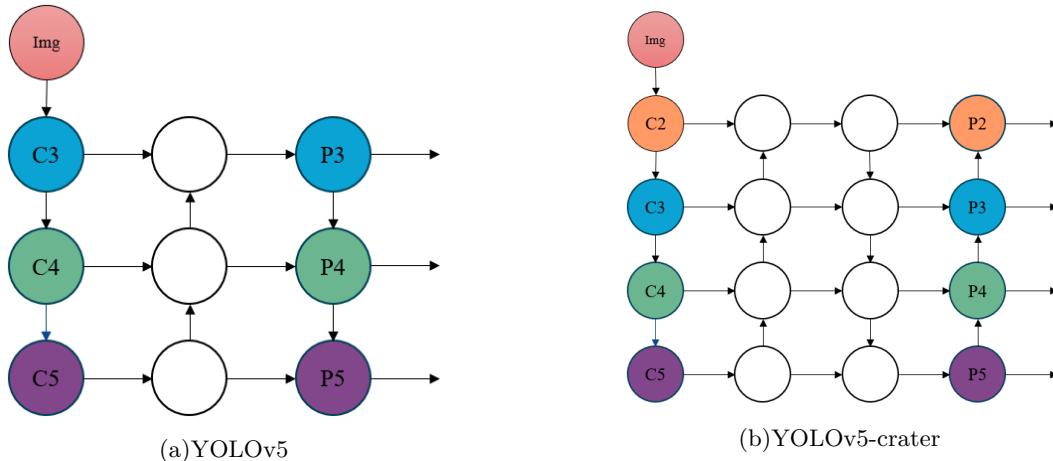
度和类别信息的张量, 用于计算损失函数。最终输出目标的边界框、类别概率以及置信度分数。

YOLOv5 提供了多种子模型以适应不同硬件条件和任务需求(用 n、s、m、l 和 x 来指代从小到大的模型参数量)。这些子模型通过调整网络深度系数和网络宽度系数来控制网络的参数量和计算量。具体而言, 网络深度系数决定了模块的数量, 影响了网络的深度; 网络宽度系数决定了特征图的通道数, 影响了网络的宽度。例如 YOLOv5n 是参数量最小的模型, 仅有 1.9M 的参数量, 适合资源受限的场景, 而 YOLOv5x 是参数量最大的模型, 具有 86.7M 的参数量, 适合对精度要求较高的任务。基于硬件条件与训练时间成本的考虑, 我们选择 YOLOv5s 作为基础模型进行实验。YOLOv5s 在参数量、计算量和精度之间取得了较好的平衡, 适合我们的研究需求。

2.2 模型改进方法

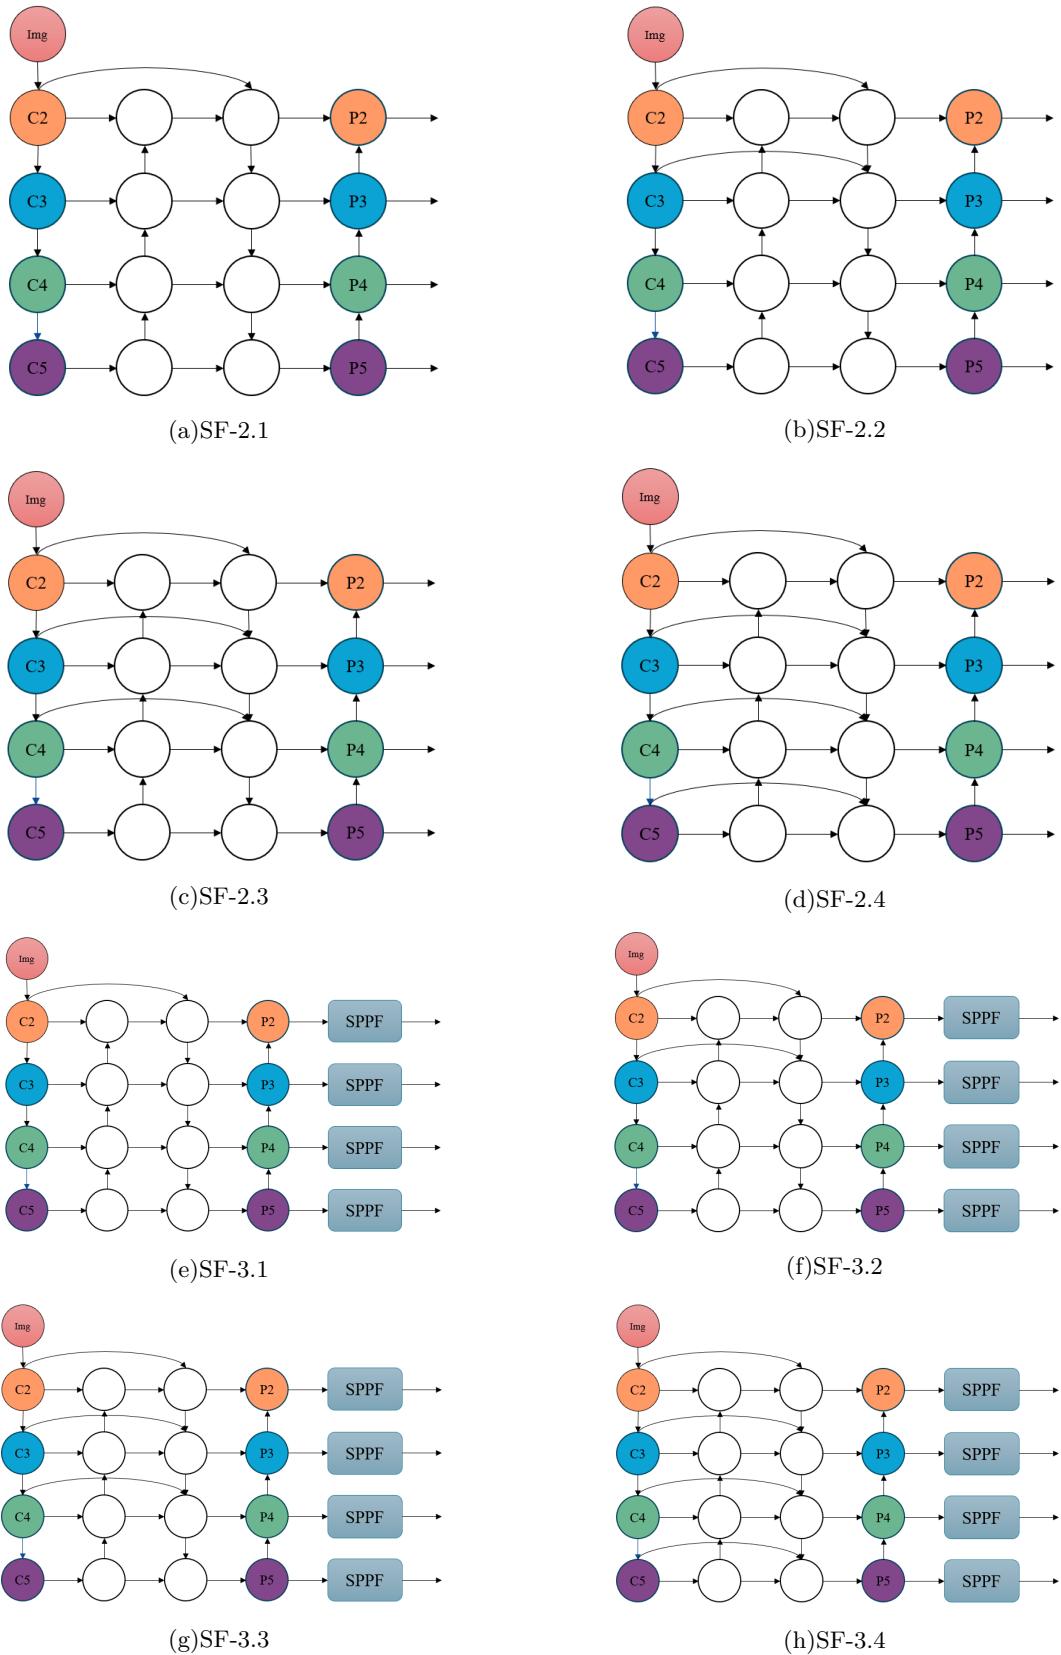
在大多场景下, YOLOv5 能够取得较好的检测结果, 尤其适用于大尺寸目标的检测。然而, 在天体表面的陨石坑检测任务中, 由于有的陨石坑尺寸较小, 遥感图像经过多次卷积操作后, 这部分陨石坑在特征图中占据的区域不足一个像素点, 导致网络难以提取和学习其特征信息。直接使用 YOLOv5 进行检测会导致漏检率和错检率升高。因此, 针对多尺度目标的识别问题, 本研究对 YOLOv5 网络进行了改进, 以提高模型的识别精度。

YOLOv5 网络结构如图3(a) 所示。针对多尺度目标检测检测, 我们的改进方案如图3(b) 所示。首先, 在主干网络中增加第四个尺度的特征提取 (C2 特征图, 160×160 像素), 以保留更多小目标的细节信息。其次, 在颈部网络中增添第四个尺度的特征融合 (P2 特征图, 160×160 像素), 并通过更小比例的锚框进行检测, 以更好地匹配小陨石坑的尺寸。**这种改进可以增强模型对不同尺度陨石坑的识别能力**, 提高了陨石坑检测的整体精度。改进后的模型被命名为 YOLOv5-crater。



注: (a) YOLOv5 特征金字塔结构。(b) 以 YOLOv5 为基础上添加了 C2 尺度的特征提取与特征融合。

图 3 YOLOv5 网络结构与针对多尺度识别识别改进后的 YOLOv5-crater 网络结构



注: (a)-(d) 为 SF-2.1 至 SF-2.4 的网络结构,(e)-(h) 为 SF-3.1 至 SF-3.4 的网络结构

图 4 以 YOLOv5-crater 为基础进行改进的的八个网络结构

为了进一步提高网络对陨石坑的识别精度, 基于 YOLOv5-crater 的网络结构, 本研究通过改进特征融合方式设计了八组实验, 分别命名为 SF-2.1、SF-2.2、SF-2.3、SF-2.4、SF-3.1、SF-3.2、SF-3.3 和 SF-3.4, 如图4所示。以下详细说明每组实验的具体改进方法以及预期效果。

实验 SF-2.1 至 SF-2.4 通过融合骨干网络中不同尺度的特征 (C2-C4) 到后续特征图中, 以增强网络的特征学习能力。这种改进能够保留更多小目标的细节信息, 同时结合高层特征的语义信息, 从而提高检测精度。

实验 SF-3.1 至 SF-3.4 在 SF-2.1 至 SF-2.4 的基础上, 于特征图输出端添加空间金字塔快速池化模块 SPPF。SPPF 模块通过多尺度池化操作, 进一步融合特征信息, 增强模型的上下文感知能力和泛化性能。这种改进旨在通过多尺度特征融合, 进一步提高陨石坑检测的精度和鲁棒性。

3 评估方法与实验结果

3.1 数据集制作

目标检测模型的性能与其训练数据集的质量密切相关。高质量的数据集能够显著提升模型的检测性能, 因此数据集的制作在本研究中占据重要地位。YOLOv5 要求的数据集标签格式为 txt 文本文件, 其中每一行数据记录了目标类别编号 (如 0、1、2...)、归一化的边界框中心点 x 坐标和 y 坐标 (坐标数值在 0-1 之间) 以及归一化的边界框宽 w 和高 h(坐标数值在 0-1 之间)。本研究使用 Labelme 软件^①对图像中的陨石坑进行标注, 并将生成的 json 格式标签文件转换为 YOLOv5 所需的 txt 格式。

基于 Melosh 提出的行星地质学较为权威的陨石坑分类体系, 选取其中较为常见的两大类陨石坑: 简单陨石坑和复杂陨石坑^[16] 作为本研究的陨石坑分类目标, 如图5所示。简单陨石坑直径一般在 4 千米以内, 坑壁陡峭, 坑缘凸起形成一个较为完整的椭圆形结构, 坑底则较为平滑呈半椭球型的碗状。简单陨石坑在光学遥感图像中的特征主要是其具有区域较大的阴影部分, 且坑边缘形状较为完整清晰可见, 这类陨石坑在天体表面数量较多。复杂陨石坑在体积规模上相比简单陨石坑更大, 较大的可以达到 50-70 千米, 坑壁较浅, 一般呈梯田结构, 坑缘存在嵌套陨石坑或变形缺失, 坑周围会存在多个凸出边缘, 坑底平坦呈平底锅状^[17]。根据坑中心是否存在撞击后物质反射可以对复杂陨石坑进一步进行分类, 针对坑中心存在中央峰的陨石坑可以分类为中央峰复杂陨石坑, 对于坑中心存在环形山的陨石坑可以分类为中央环复杂陨石坑^[18]。复杂陨石坑在光学遥感图像中的特征为其明亮区域占据比例较大, 阴影区域较小, 且随时间的演化其边缘特征较为浅显, 并没有简单陨石坑那样显著。

数据集中的图像主要来源于 NASA 公开的遥感数据^②, 包括信使号任务 (Messenger)、火星勘测轨道器任务 (MRO)、月球勘测轨道器任务 (LRO) 以及黎明号任务 (Dawn) 所获取

^①<https://www.labelme.io/>

^②<https://photojournal.jpl.nasa.gov/>

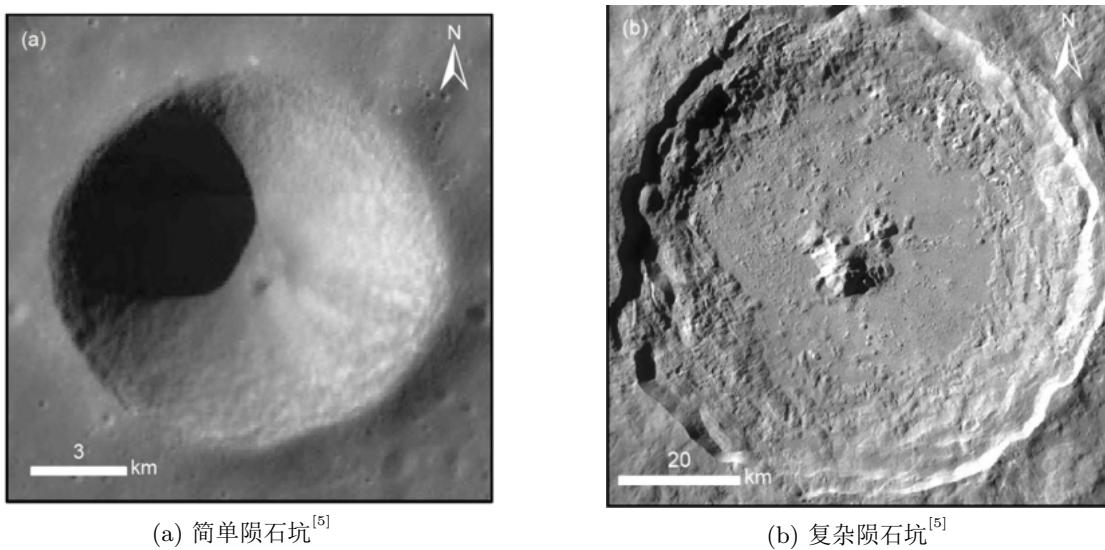
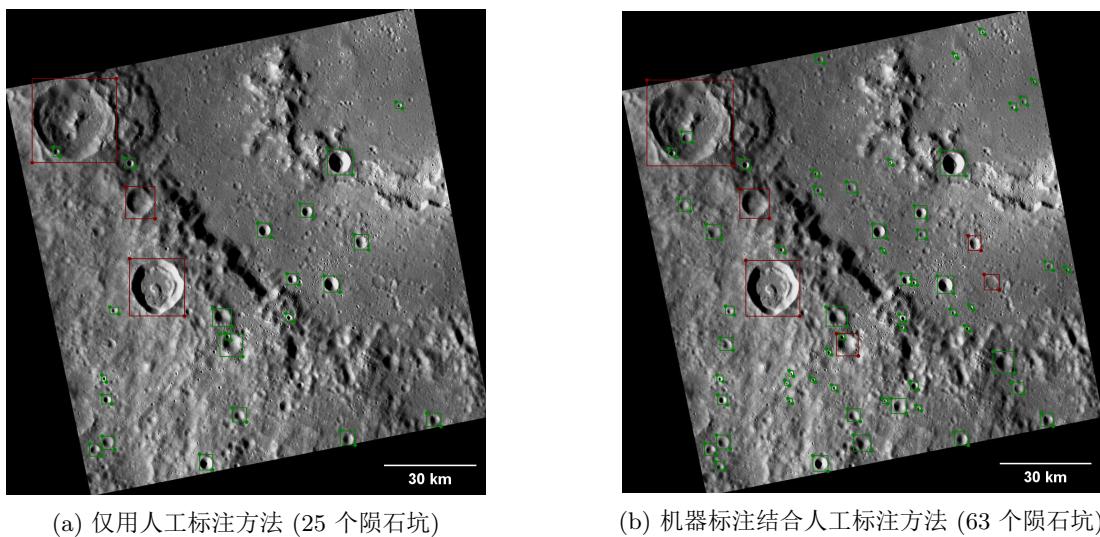


图 5 两种陨石坑形态特征对比

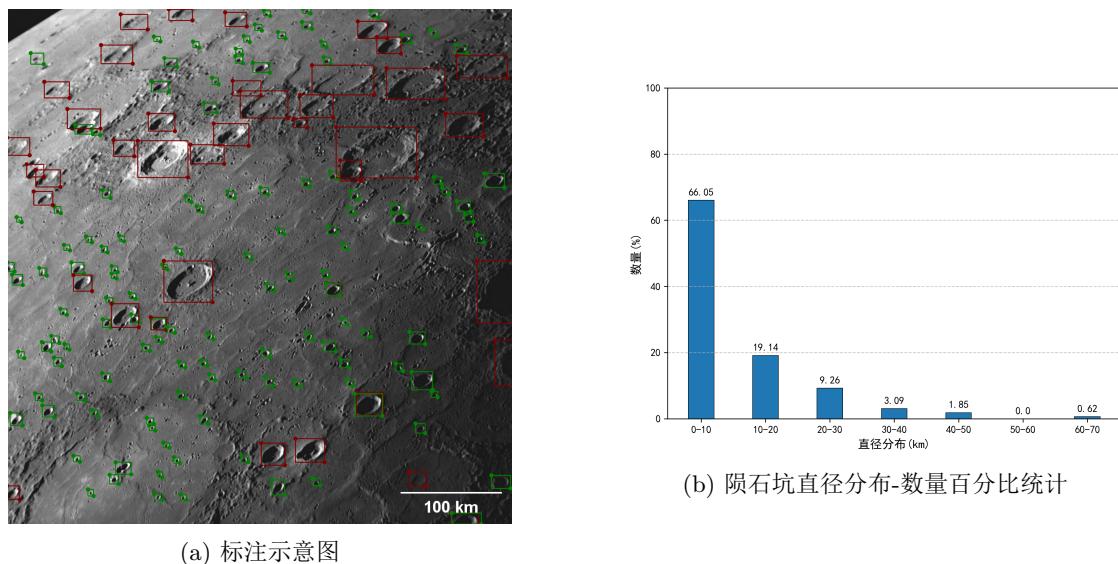
的水星、火星、月球以及谷神星表面的光学遥感图像。本研究从中选取了包含大量陨石坑的图像进行标注，数据集由灰度图像和少量彩色图像组成，涵盖了不同的光照条件，**数据集影像数据的空间分辨率范围从 100 米/像素到 500 米/像素不等**。初始数据集包含 227 张图像，按 9:1 的比例划分为训练集和验证集。为进一步扩充数据集，我们采用机器标注结合人工修正的方法：使用 227 张小规模数据集对模型进行预训练，并使用训练好的模型对新增图像中的陨石坑进行检测识别，将识别生成的标签文件作为标注文件。这种机器标注方法可以识别并框定出大多数特征明显的陨石坑，但会存在很多漏检（未标注出的陨石坑）和错误检测（检测框类别错误或检测框位置错误）。经过机器标注后的图像数据在标注软件中根据不同种类陨石坑特征作为先验性定义来进行人工修正，将模型漏检的陨石坑人工标注出来，模型分类错误的检测框根据框内陨石坑实际分类进行标签修正，而模型给出错误位置的检测框进行手动修正到实际陨石坑位置。这种机器标注结合人工修正的标注方法有效的提高了深度学习训练数据集的标注效率，减少了一定的工作量。相比原 227 张陨石坑数据集，同一张图片在机器标注辅助人工标注的方法下增添了更多的陨石坑样本，实现了单张图像的样本扩充，如图6所示。

最终，数据集扩充至 640 张图像，其中 540 张为训练集，100 张为验证集。**数据集共标注 40528 个陨石坑样本，平均每张图像标注 63 个陨石坑样本。其中简单陨石坑标注数量为 27472 个，复杂陨石坑标注数量为 13056 个。**标签文件以图片左上角为原点，记录归一化的边界框中心点坐标和宽高以及陨石坑类别信息。图7展示了数据集中一张水星表面遥感图像的标注示例及对其中所有陨石坑的直径分布-数量百分比统计信息。该影像来源于信使号探测器的窄角相机所拍摄水星表面从部分熔岩平原眺望左上角地平线的图片，空间分辨率为 400 米/像素，整张图片跨越尺度为 410 千米，探测器拍摄高度为 15900 千米，拍摄时间为



注: 图像来源于信使号获取的水星表面的一张光学遥感图像, 空间分辨率为 125 米/像素。全人工标注方法仅可标注出少量陨石坑样本, 对于一些较小陨石坑难以用肉眼识别, 图(a)仅标注出 25 个陨石坑样本。图(b)在机器标注的辅助下进行人工标注修正, 提高了标注效率, 增加了一定样本数, 共标注出 63 个陨石坑样本。红色框表示复杂陨石坑, 绿色框表示简单陨石坑

图 6 全人工标注结果和机器辅助人工标注结果对比



注: 图像 (a) 来源信使号拍摄的水星表面光学遥感图像, 空间分辨率为 400 米/像素。标注过程使用矩形框对陨石坑进行框定, 红色框表示复杂陨石坑, 绿色框表示简单陨石坑, 共标注 162 个陨石坑, 其中 122 个简单坑和 40 个复杂坑。(b) 为对 (a) 图中陨石坑直径分布和占据所有陨石坑总数的百分比统计信息。

图 7 水星表面遥感图像陨石坑标注示例及陨石坑直径分布-数量百分比统计信息

2009 年 9 月 29 日。分别使用绿色框和红色框标注简单坑和复杂坑，共标注 162 个陨石坑。

为增强数据集的多样性和模型的泛化能力，YOLOv5 在训练过程中对图像进行随机缩放、旋转和裁剪等数据增强操作。这些操作有效的扩充了数据集，进而提高了模型对陨石坑的检测精度。

3.2 评估指标

目标检测模型的性能通常通过多分类平均精度 (mean Average Precision, mAP) 来进行定量评估，mAP 基于交并比 (Intersection over Union, IoU) 的概念定义。IoU 衡量模型预测框与真实框的重叠程度，其计算公式为：

$$\text{IoU}_{\text{pred}}^{\text{truth}} = \frac{|A \cap B|}{|A \cup B|} , \quad (1)$$

其中，A 和 B 分别表示预测框和真实框。当 IoU 为 1 时，表示两个框完全重叠；当 IoU 为 0 时，表示两个框无重叠。早期目标检测领域广泛使用的 PASCAL VOC 数据集便将 IoU 阈值定为 0.5 来定义正确检测，这一标准被后续研究沿用，成为学术界和工业界的默认基准。贾世娜^[19]、邱天衡等^[20] 均在其针对 YOLOv5 模型改进的研究中使用了 IoU 阈值为 0.5 的设定。如阈值过高，许多合理但不够精确的检测会被判定为错误检测，使模型优化方向更注重于检测框的位置准确程度而忽视分类的精准度。而如果阈值过低，会使得很多检测框与实际物体位置偏差较大。IoU 阈值为 0.5 的设定较好的平衡了检测框的位置与分类的关注程度，因此本研究后续评估过程均将 IoU 阈值设定为 0.5。

基于 IoU 的计算结果，可以进一步评估模型的查准率 (Precision, P) 和查全率 (Recall, R)。查准率和查全率的定义如下：

$$P = \frac{TP}{TP + FP} , \quad (2)$$

$$R = \frac{TP}{TP + FN} , \quad (3)$$

其中，TP(True Positive) 表示 IoU 大于 0.5 的预测框的个数，FP(False Positive) 表示 IoU 小于 0.5 的预测框的个数，FN(False Negative) 表示未检测到的真实框的个数。查准率 P 衡量模型预测结果的准确性，而查全率 R 衡量模型对真实目标的检测全面性。

置信度 (Confidence) 是目标检测中的另一重要指标，用于衡量模型对检测到的目标存在的确定性以及预测框定位的准确性。置信度由当前边界框内存在目标的概率 P_{obj} 和预测框与真实框之间的交并比计算得出：

$$\text{Confidence} = P_{\text{obj}} \times \text{IoU}_{\text{pred}}^{\text{truth}} , \quad (4)$$

模型根据置信度阈值筛选预测框，大于阈值的框被归为 TP 或 FP，小于阈值的框被归为 FN。通过调整置信度阈值，可以获得不同的 P 和 R 值，进而绘制 P-R 曲线。平均精度 (Average Precision, AP) 定义为 P-R 曲线下的面积：

$$AP = \int_0^1 P(R) dR , \quad (5)$$

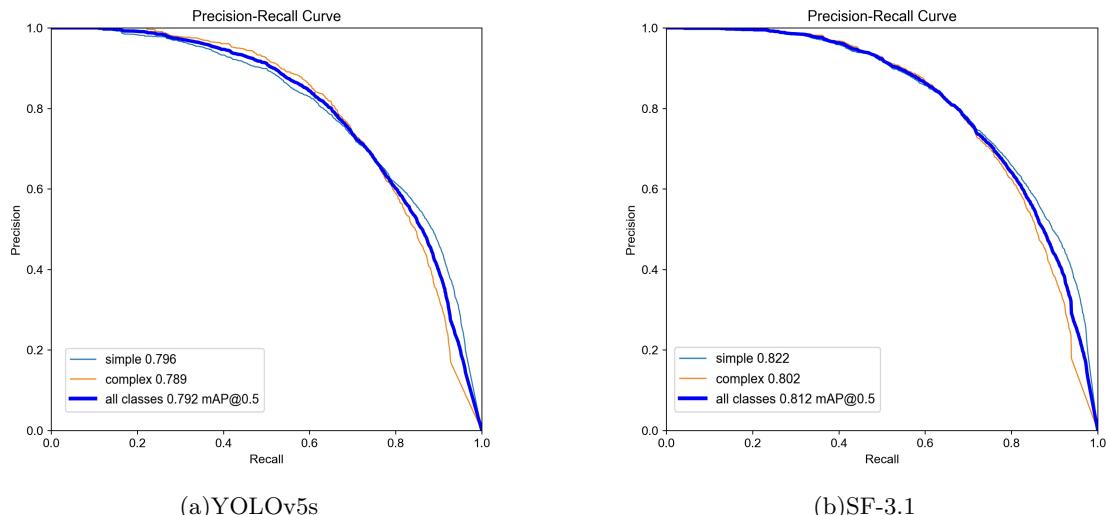
AP 衡量模型对单类别目标的检测精度。对多类别目标检测任务, 取各类别 AP 的平均值即可得到 mAP。**mAP** 是目标检测领域评估模型整体性能的定量分析指标, 其值越高, 表明模型在准确定位目标的同时, 能够尽可能覆盖所有真实目标。在目标检测任务中, mAP 指标可以全面反映模型在定位精度和分类准确性上的综合性能并通过多类别平均缓解类别不均衡问题。其基于 P-R 曲线的计算反映了模型在不同置信度阈值的表现, 因此本研究后续对模型性能的定量分析均以 mAP 作为评估标准。

3.3 实验结果

实验所使用的硬件为: CPU: 11th GEN Intel(R) Core(TM) i7-11700, GPU: NVIDIA GeForce RTX3080, Windows11。

3.3.1 修改特征融合方式的对比实验及其结果

根据制作的 640 张陨石坑数据集对 YOLOv5s 及改进的模型进行训练, 模型训练参数设置如下: 训练轮次 epochs 均设置为 500 轮(将整个数据集图片训练完为一个轮次, 一共训练 500 轮, 当最后 100 轮的训练结果没有显著提升的情况下可以提前终止训练); batchsize 为 4(每批次处理 4 张图片); 训练的 dataloader workers 为 8 个(数据集处理器数量, 数值越高对 GPU 硬件的要求越高)。

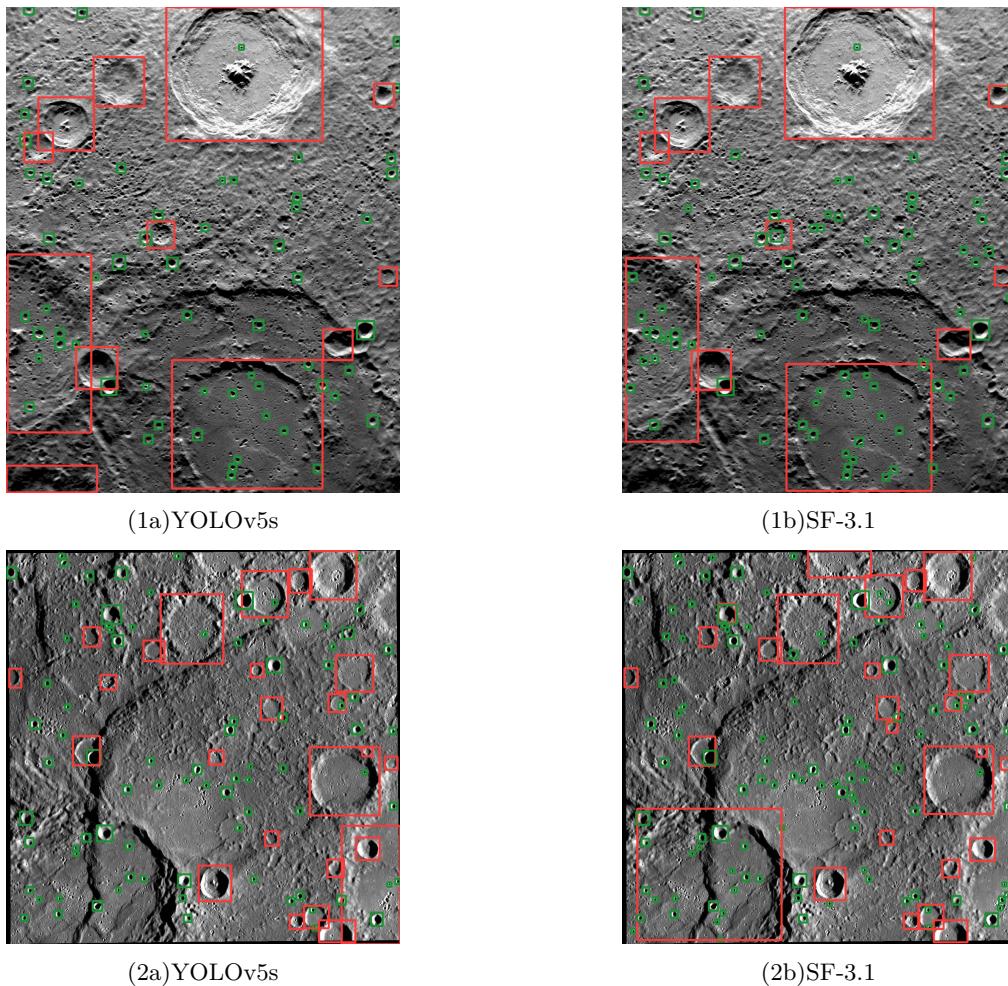


注: 浅蓝色代表简单陨石坑的平均精度曲线, 橙色代表复杂陨石坑的平均精度曲线, 深蓝色粗线代表多分类平均精度曲线。

图 8 YOLOv5s 与改进后的最佳模型 SF-3.1 在陨石坑数据集的训练结果获取的 P-R 曲线

使用原始 YOLOv5s 网络在陨石坑数据集训练后获得的多分类平均精度 (mAP@50) 为 79.2%(@50 表示 IoU 阈值设定为 0.5), 训练时长为 1.324 小时。基于 YOLOv5-crater 网

络改进的八个模型在陨石坑数据集训练后获得的多分类平均精度 (mAP@50) 分别为 80.4%、80.6%、80.9%、80.4%、81.2%、81%、81% 和 80.7%，训练时长分别为 2.102 小时、2.051 小时、2.237 小时、2.385 小时、2.088 小时、2.493 小时、2.514 小时和 2.577 小时。实验结果表明，相比未改进的原始 YOLOv5s 模型，SF-3.1 通过引入并融合小尺度特征 C2，保留了更多小陨石坑的细节信息，提升了多分类检测的精度，使模型的 mAP@50 从 79.2% 提高到了 81.2%，证明了新添加的特征融合路径 C2-P2 的有效性。



注：图 (1a)、图 (1b) 来源信使号所拍摄的水星表面光学遥感图像，空间分辨率为 295 米/像素，图 (2a)、图 (2b) 来源信使号所拍摄的水星表面光学遥感图像，空间分辨率为 245 米/像素。绿色框为简单陨石坑的识别，红色框为复杂陨石坑的识别。图 (1a) 中 YOLOv5s 识别出简单坑 61 个，复杂坑 12 个，共 73 个陨石坑，检测速度为 29 毫秒；图 (1b) 中 SF-3.1 识别出简单坑 88 个，复杂坑 11 个，共 99 个陨石坑，检测速度为 54 毫秒。图 (2a) 中 YOLOv5s 识别出简单坑 85 个，复杂坑 25 个，共 110 个陨石坑，检测速度为 34 毫秒；图 (2b) 中 SF-3.1 识别出简单坑 119 个，复杂坑 26 个，共 145 个陨石坑，检测速度为 35 毫秒。

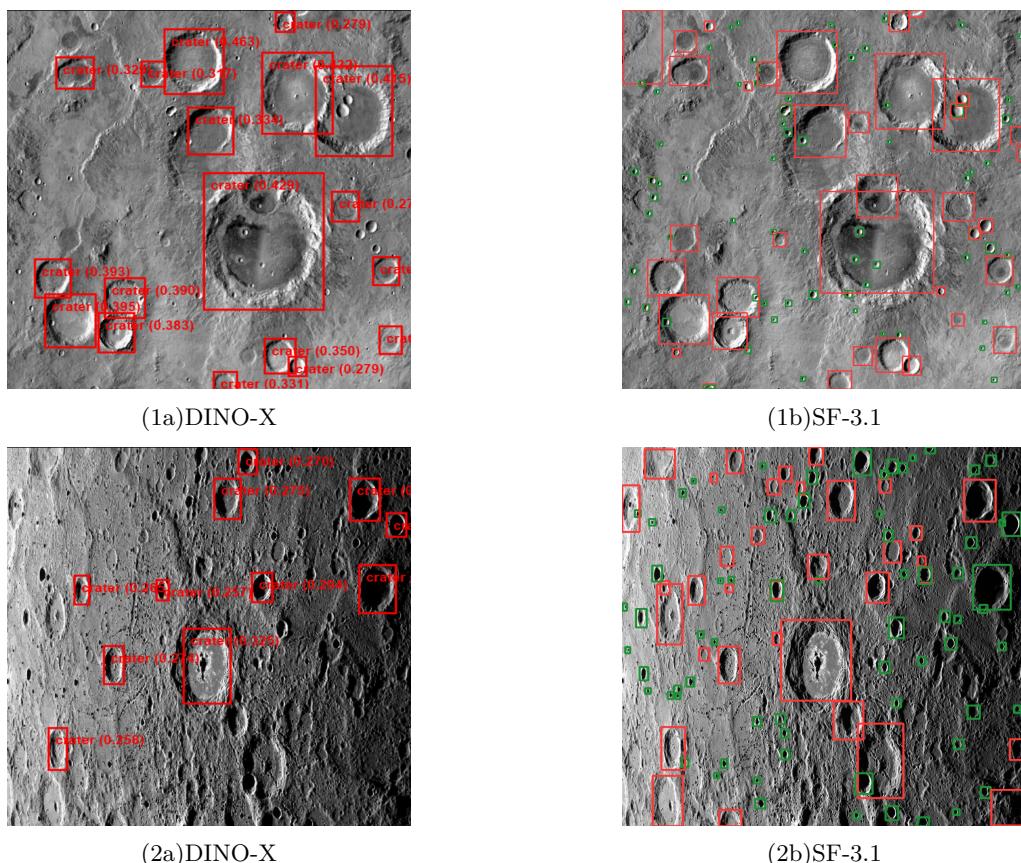
图 9 SF-3.1 与 YOLOv5s 原模型的陨石坑识别可视化结果对比

图9给出了改进前的 YOLOv5s 原模型和改进后的最佳模型 SF-3.1 在简单陨石坑与复杂陨石坑识别的可视化结果对比, 左列为 YOLOv5s 的识别结果, 右列为 SF-3.1 的识别结果。统计标签结果可知, 改进后模型相较原模型在两张图像上的简单陨石坑的识别数量分别提升了 27 个和 34 个, 陨石坑识别总数分别提升了 26 个和 35 个, 因此可以证明本研究对小尺寸目标识别方面的改进是有效的。

在检测速度方面, 模型对测试集单张图像的检测时间在 100 毫秒以内, 基本实现了快速自动化的实时检测。这一性能使其能够作为探测器导航的参考信息, 为未来深空探测任务提供技术支持。

3.3.2 与主流目标检测模型的识别结果对比

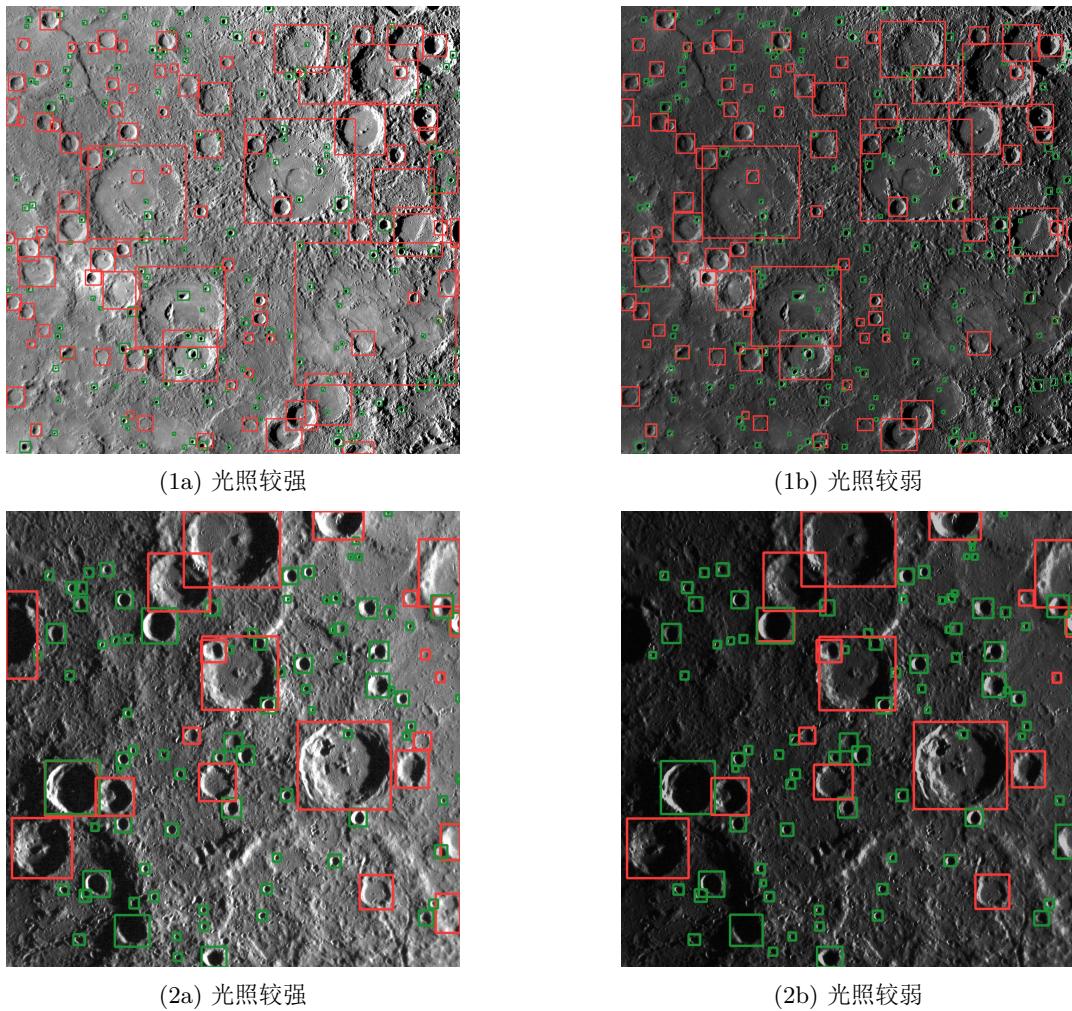
实验选取了两张类地天体表面的光学遥感图像, 在训练获取的最佳模型 SF-3.1 上进行了陨石坑识别测试, 并与 IDEA Research 于 2024 年 11 月提出的开放世界目标检测通用大模型 DINO-X^[21] 进行了对比。



注: 左列为 DINO-X 目标检测通用大模型对陨石坑的识别结果; 右列为本研究训练的最佳模型的识别结果, 绿色框为简单陨石坑, 红色框为复杂陨石坑。

图 10 改进模型与当今主流通用目标检测模型的识别结果对比

图10展示了两种模型的可视化识别结果，其中左列为DINO-X模型的识别结果，右列基于YOLOv5改进后的最佳模型模型SF-3.1的识别结果。实验结果表明，DINO-X模型在给定提示词的情况下能够识别部分特征明显的陨石坑，但对大部分小型陨石坑存在漏检现象，且无法对识别结果进行分类。相比之下，本研究改进的模型通过本文标注的陨石坑数据集的训练，能够有效识别遥感图像中的大部分陨石坑并进行正确分类，在识别总数量上要优于DINO-X模型。此外，由于模型针对小尺度目标识别进行了改进，对于一些DINO-X模型无法识别出的较小的简单陨石坑也可较为准确地识别出来。



注：图(1a)、图(1b)来源信使号所拍摄的水星表面光学遥感图像，空间分辨率为500米/像素，图(2a)、图(2b)来源信使号所拍摄的水星表面光学遥感图像，空间分辨率为310米/像素。绿色框为简单陨石坑，红色框为复杂陨石坑。图(1a)识别出简单坑162个，复杂坑95个，共257个陨石坑；图(1b)识别出简单坑158个，复杂坑93个，共251个陨石坑。图(2a)识别出简单坑87个，复杂坑23个，共110个陨石坑；图(2b)识别出简单坑86个，复杂坑17个，共103个陨石坑。

图11 不同光照条件下的陨石坑识别结果对比

图11给出了训练获取的最佳模型 SF-3.1 在两张光学遥感图像上针对不同光照条件下的识别结果对比。本研究通过图像处理方法对原图像进行亮度调整, 来模拟太阳高度角较低时的光照条件, 左列为光照较强时模型的识别结果, 右列为光照较弱时模型的识别结果。从统计结果可以发现, 在光照较强时, 模型对陨石坑的识别总数分别为 257 个和 110 个, 当光照变弱时模型对陨石坑的识别总数分别降至 251 个和 103 个。不同光照条件下的陨石坑识别总数变化量不超过总识别数量的 10%, 可以证明本研究的陨石坑识别模型在不同光照条件下具有较好的鲁棒性。

3.3.3 数据集数量变化与模型改进对平均精度的影响

数据集中图像数量的增加通常能够提升目标检测模型的平均精度, 但是由于检测对象的稀有度(濒危动物)、高标注成本(医学影像病理学标注)、数据的敏感性(个人隐私或军事安全)以及前沿科技领域的数据开源限制等因素, 训练数据并非可以无限量低成本获得。本节将针对小样本数据集的训练任务进行实验, 探讨模型改进和数据集数量变化对模型精度的影响。通过对前文构建的 640 张陨石坑数据集进行梯度式分割, 对比 SF-3.1 模型与 YOLOv5s 模型, 使用 290 至 640 张数据集(每 50 张为增量)进行训练, 实验结果如图12所示。

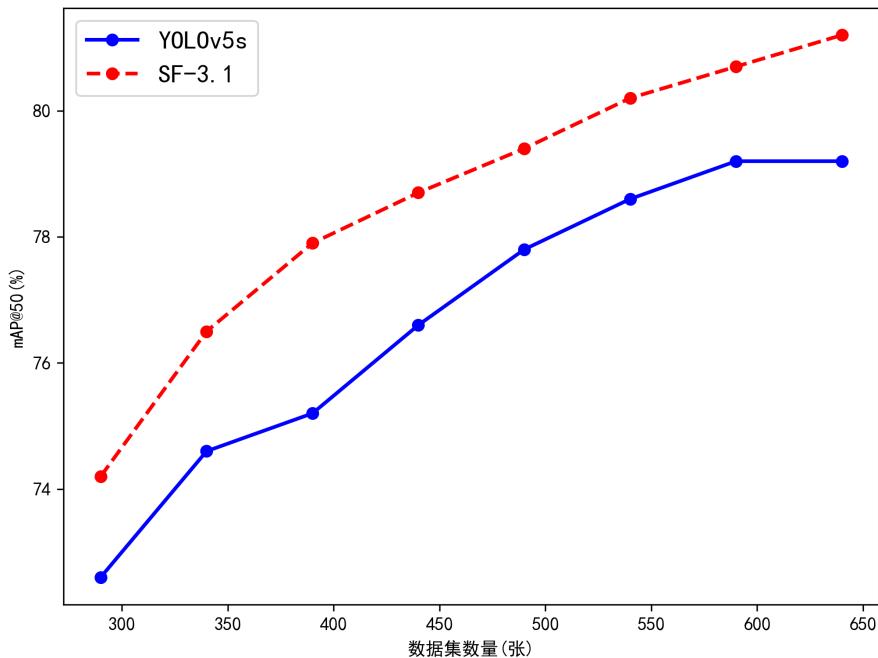


图 12 数据集数量变化与模型改进对陨石坑识别平均精度的影响

从实验结果可以发现, 当数据集数量为 390 张时, YOLOv5s 模型的平均精度为 75.2%, 而 SF-3.1 模型的平均精度为 77.9%, 提升了 2.7%。值得注意的是, YOLOv5s 模型需要将数据集增加到 490 张才能达到 77.8% 的精度。这表明, 模型的改进相当于增加约 100 张数据集的性能提升。此外, 当数据集达到 640 张时, YOLOv5s 模型的平均精度为 79.2%, 与

590 张数据集时的精度相同；而 SF-3.1 模型在 640 张数据集时的平均精度为 81.2%，较 590 张数据集时的 80.7% 提升了 0.5%。这一结果证明，本研究所提出的模型改进方法相比原模型而言，可以使用较少数量的数据集来达到较高的模型精度，适用于训练样本数量较少的小样本目标检测任务并在一定程度减少数据标注的工作量。

4 总结与展望

当前，目标检测模型在开放世界的检测任务中已取得较高准确率和回归率，但在天文领域的陨石坑识别任务中，由于缺乏高质量的数据集，目标检测模型的检测精度难以满足科研需求。为解决这一问题，本文基于类地天体表面的光学遥感图像制作了供天文学家使用的陨石坑识别与分类数据集，提出了机器识别辅助人工标注的数据集标注方法，提高了标注效率。进而将陨石坑分为复杂陨石坑和简单陨石坑两类，以支持模型在检测过程中自动区分不同形态的陨石坑。实验表明，使用该数据集训练的目标检测模型对陨石坑的识别在验证集上具有较高的查准率和查全率。通过对网络多尺度特征提取和特征融合方式的改进，模型的多分类检测的平均精度 (mAP@50) 从 79.2% 提升至 81.2%，提高了对小目标陨石坑的识别精度。

通过实验证明了在小规模数据集的模型训练任务中，对模型的改进带来的性能提升相当于增加约 100 张训练数据的效果，在保证精度的同时降低了数据标注的工作量，对于小样本数据集的训练任务具有一定参考价值。训练后的模型在陨石坑检测任务中表现出较高的检测精度，漏检率与错检率较低，在准确定位陨石坑位置的同时能够尽可能覆盖所有真实目标，且对不同光照条件具有较好的鲁棒性。此外，模型对单张图像的检测时间在 100 毫秒以内，满足实时检测的需求。该研究可以为未来深空探测任务中的地物目标识别与障碍物规避提供一定参考。

尽管当前模型的精度尚未达到实际工程任务的要求，未来我们将通过增加数据集规模、改进网络结构等方式，进一步提升模型对陨石坑特征的学习能力。随着基础科学研究领域专业大模型的快速发展，天文领域专用模型的需求日益凸显。我们的陨石坑识别与分类模型及陨石坑数据集可作为其中的重要组成部分，通过整合多模态数据，支持更广泛的天文目标检测任务。

5 致谢

感谢国家自然科学基金面上项目(12273092)，上海市 2022 年度“科技创新行动计划”港澳台科技合作项目(22590760900)对本研究的资助，感谢李力刚研究员对本文提出的建设性意见。

参考文献:

- [1] 陈动, 胡凡, 张立强, et al. 中国科学: 地球科学, 2024, 54(06): 1745
- [2] 张腾宇, 金双根, 崔祜涛. 深空探测学报, 2014, 1(02): 123
- [3] 赵丹冬. [D]. 吉林: 吉林大学, 2022. 硕士论文
- [4] 王丹, 丁孝忠, 韩同林, et al. 地球学报, 2017, 38(06): 971
- [5] 岳宗玉, 史珂, 邸凯昌, et al. 中国科学: 地球科学, 2023, 53(11): 2482
- [6] 丁萌, 曹云峰, 吴庆宪. 宇航学报, 2009, 30(03): 1243
- [7] 曹雅盟. [D]. 北京: 中国地质大学, 2020. 硕士论文
- [8] Pan L, Quantin-Nataf C, Breton S, et al. Nature communications, 2019, 10(1): 4257
- [9] 王影. [D]. 安徽: 合肥工业大学, 2012. 硕士论文
- [10] 熊月容. [D]. 湖南: 湖南大学, 2021. 硕士论文
- [11] Maass B, Woicke S, Oliveira W M, et al. Journal of Guidance, Control, and Dynamics, 2020, 43(8): 1414
- [12] 胡涛, 贺亮, 曹涛, et al. 载人航天, 2020, 26(05): 656
- [13] Downes L, Steiner T J, How J P. AIAA SciTech 2020 Forum. Florida: AIAA, 2020: 1838
- [14] Hu T, Zhao C, Qian Z, et al. 2021 33rd Chinese Control and Decision Conference (CCDC). Yun Nan: IEEE, 2021: 1748
- [15] Tewari A, Verma V, Srivastava P, et al. Planetary and Space Science, 2022, 218: 105500
- [16] MELOSH H, IVANOV B. Annual Review of Earth and Planetary Sciences, 1999, 27(1): 385–415
- [17] 王琤. [D]. 湖南: 武汉大学, 2009. 博士论文
- [18] 何姝珺, 陈建平, 李珂, et al. 地学前缘, 2012, 19(06): 83–89
- [19] 贾世娜. [D]. 江西: 南昌大学, 2022. 硕士论文
- [20] 邱天衡, 王玲, 王鹏, et al. 计算机工程与应用, 2022, 58(13): 63–73
- [21] Ren T, Chen Y, Jiang Q, et al. arXiv preprint arXiv:2411.14347, 2024

Automatic Crater Detection and Classification on Terrestrial Planets Using YOLOv5

YUAN Xutong^{1,2}, LI Xizhi¹

(1. Shanghai Astronomical Observatory, Chinese Academy of Sciences, Shanghai 200030, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In deep space exploration landing missions, the probe selects landing sites based on real-time images of celestial surfaces acquired by sensors. These images contain complex terrain features of terrestrial planet surfaces. As one of the prominent terrain characteristics, craters can serve as navigation landmarks while requiring avoidance during descent. However, the diversity of craters in scale, illumination, and quantity poses significant challenges for real-time detection and identification. Traditional image processing techniques are time-consuming and prone to missed or false detections, failing to meet real-time rapid detection requirements. In recent years, artificial intelligence has achieved remarkable progress in object detection, with various efficient algorithms emerging. This study proposes an improved

intelligent crater detection model based on YOLOv5, along with constructing a dedicated crater dataset for training. To adapt to detection requirements for craters of different scales, the research enhances the model's network architecture by adding small-scale feature extraction modules and optimizing feature fusion methods. Experimental results demonstrate that the improved model increases mean average precision (mAP@50) on the crater dataset from 79.2% to 81.2%, equivalent to approximately 2% improvement from adding about 100 training images. It enhances recognition rates for small-target craters while incorporating crater classification capabilities. The model shows significant application value in few-shot detection tasks with limited training data. Compared with current mainstream open-world object detection general models like DINO-X, the improved model exhibits distinct advantages in crater recognition accuracy and demonstrates better robustness under varying illumination conditions. This research provides important references for real-time crater detection and related tasks, demonstrating its potential application value in deep space exploration missions.

Key words: Deep space exploration; Terrestrial planets; Crater; Object detection; YOLOv5