



撞击坑识别方法研究综述

陈动¹, 胡凡¹, 张立强², 吴昀昭³, 杜建丽^{3,4*}, Jiju PEETHAMBARAN⁵

1. 南京林业大学土木工程学院, 南京 210037;

2. 北京师范大学地理科学学部遥感科学国家重点实验室, 北京 100875;

3. 中国科学院紫金山天文台, 南京 210023;

4. 中国科学院空间目标与碎片观测重点实验室, 南京 210023;

5. Department of Mathematics and Computing Science, Saint Mary's University, Halifax, NS B3H 3C3, Canada

* 通讯作者, E-mail: dujianli@pmo.ac.cn

收稿日期: 2023-07-15; 收修改稿日期: 2024-02-20; 接受日期: 2024-02-22; 网络版发表日期: 2024-04-30

国家自然科学基金项目(41925006、12003075、42371383和42271450)资助

摘要 撞击坑是宇宙中小天体以超高速撞击固态天体表面形成的构造结构, 撞击作用是天体演化最重要的驱动力, 撞击坑为固态天体形成、演化和撞击历史等方面研究提供了重要线索. 本文对撞击坑对象、撞击坑数据、撞击坑识别算法和撞击坑应用等维度进行了综述. 全面描述了遥感观测数据中撞击坑所呈现出的几何纹理、光照和形貌特征. 重点总结了月球、火星、水星、金星四颗“类地行星”和小行星-谷神星撞击坑遥感数据和矢量编目数据库. 详细探究了传统方法、机器学习方法和深度学习方法在撞击坑分类、分割和识别方面的研究进展. 在此基础上, 着重分析了撞击坑识别中存在的问题, 并给出相应的解决方案. 最后, 在撞击坑算法应用方面进行了探讨与展望.

关键词 类地行星, 深空探测, 撞击坑, 撞击坑识别, 深度学习

1 引言

自伽利略1609年(Galilei, 1610)首次使用望远镜清晰地观测到月球表面的撞击坑以来, 探测仪器和识别方法不断进步, 不同天体上分布的各种尺寸和构造的撞击坑逐渐展现在研究者的视野中. 这些撞击坑是由高速飞行的陨石、彗星或小行星撞击天体表面形成的近圆形凹陷区域, 直径从亚千米级到数百公里不等. 研究撞击坑可以深入了解撞击事件的作用机制, 并揭示天体间相互碰撞对行星表面形态及其物理化学成分的

塑造和变化过程, 为理解天体撞击对生命起源、进化, 甚至灭绝所产生的影响提供了关键的科学依据.

在行星科学研究和深空探测工程任务中, 撞击坑都具有重要的研究价值. 在行星科学研究方面, 撞击坑相关信息能够揭示行星地形地貌(王丹等, 2017), 确定行星地质年代(Tanaka, 1986), 分析行星自转轴偏移(Smith等, 2022), 推断岩浆活动时空模式(Thomas等, 2015), 推演行星演化过程(Pan等, 2019)并追踪水和生命迹象(Salese等, 2020). 譬如, 基于撞击坑“尺寸-频率”关系定年法, 通过统计“维京号”(Viking)火星影像中不

中文引用格式: 陈动, 胡凡, 张立强, 吴昀昭, 杜建丽, Peethambaran J. 2024. 撞击坑识别方法研究综述. 中国科学: 地球科学, 54(6): 1745–1768, doi: [10.1360/SSTe-2023-0152](https://doi.org/10.1360/SSTe-2023-0152)

英文引用格式: Chen D, Hu F, Zhang L, Wu Y, Du J, Peethambaran J. 2024. Impact crater recognition methods: A review. Science China Earth Sciences, 67(6): 1719–1742, <https://doi.org/10.1007/s11430-023-1284-9>

同地质单元内的撞击坑, 将火星地质年代分为四个地质时期; 王丹等(2017)通过解析月球高分辨率卫星影像, 在“第谷撞击坑”等地区发现了冻融地貌, 与地球上发现的冻融地貌特征基本一致. 在深空探测工程任务中, 撞击坑也被广泛应用于着陆器选址(Wu B等, 2022)、探测器导航(Maass等, 2020)、行星地形地貌制图(Trask和Guest, 1975)等任务. 譬如, 基于撞击坑高精度形貌图, “嫦娥四号”着陆器选择月球背面的“冯·卡门撞击坑”着陆, 成功实现了人类探测器首次月背软着陆(Liu J J等, 2019); 基于撞击坑实时检测与匹配算法, Maass等(2020)提出的自适应陨石坑导航系统实现了着陆器的定位、定姿与导航.

行星测绘遥感技术是深空探测的核心技术, 利用轨道器、着陆器、巡视器等平台获取的可见光影像、多光谱、高光谱、微波、激光雷达等遥感数据是开展行星观测最主要的数据源, 是对行星进行地形地貌定性和定量分析的基础(邸凯昌等, 2021). 自1958年以来, 人类已经开展深空探测任务200多次, 覆盖了太阳系内包括月球、行星、小行星、彗星与太阳等不同类型天体. 这些任务为深空探测积累了数量庞大、类型丰富的行星遥感数据, 致使早期高成本且低效率的撞击坑目视解译和人工标注方法已不能满足撞击坑信息提取全面性和精细度的需求. 深度学习等人工智能技术的迅速崛起为各类复杂撞击坑甚至坑群的形貌特征的提取和分析提供了可能, 为深空探测工程和行星科学研究提供了重要的数据支撑. 在此背景下, 本文从撞击坑对象特征、撞击坑多模态遥感数据、撞击坑识别算法、撞击坑下游任务等方面展开介绍和讨论, 并对撞击坑探测技术的发展和前景进行展望.

2 撞击坑特征

撞击坑特征主要包括几何纹理特征、光照明暗特征和地形地貌特征等(图1). 深入理解和认知撞击坑本身的先验特征, 对于撞击坑的先验建模、语义分割、目标探测及其地形地貌分析等多方面都具有重要意义. 因此, 传统的撞击坑识别方法广泛采用规则约束、统计分析、回归分析、概率估计、最优化等策略来有效提取撞击坑特征并精确识别撞击坑. 而机器学习方法则更多侧重于撞击坑的特征构建、特征变换、特征选择和特征提取. 在深度学习大行其道的当下, 对撞击

坑特征的深度挖掘有助于更好地进行撞击坑特征的上下文表征、特征增强、特征融合、特征迁移, 进而辅助设计出面向撞击坑探测的深度感知网络.

(1) 几何纹理特征. 撞击坑的几何特征是指其呈现出圆形或近似圆形的几何形状. 在撞击发生时, 能量会从撞击点向四周扩散, 由于能量传递的对称性导致其形成一个由中心向四周逐渐减弱的能量梯度, 从而造成了撞击坑的圆形或者近似圆形的几何结构. 鉴于这一几何特性, 广泛采用最小二乘拟合、随机采样一致性、霍夫变换、圆或椭圆模板匹配等算法对撞击坑进行先验建模. 然而, 当地表存在斜坡、山脉、河床等地形, 或遭到风化侵蚀、二次撞击等影响时, 部分撞击坑的形状可能会产生偏差. 此外, 基于不同地图投影生产的遥感影像数字产品也可能影响撞击坑的几何形状. 譬如, 采用圆柱投影可能导致图像畸变, 从而使撞击坑呈现椭圆形, 在高纬度地区尤为显著. 因此采用恰当的投影方式, 例如方位投影, 在一定程度上可以缓解由投影引起的几何形变.

撞击坑纹理特征是指由撞击事件在行星表面形成的特征和纹路. 譬如, 由撞击事件形成的撞击坑边缘环形脊线纹理, 在撞击事件发生时由冲击波传播和地质应力引起的撞击坑放射状条纹, 由撞击坑坑壁坍塌形成的从坑壁向下延伸的堆积物纹理. 另外, 撞击坑周围的岩石碎片和喷出物也会形成不规则的形状和纹理. 针对这些纹理特征, 首先可以通过形态学操作对其进行纹理增强, 然后结合灰度共生矩阵(Haralick等, 1973)或KLT(Kanade-Lucas-Tomasi)算法(Tissainayagam和Suter, 2004)等方法来识别撞击坑的分布区域, 并进一步精确提取撞击坑.

(2) 光照明暗特征. ① 坑内存在阴影区域与光亮区域. 太阳光线受到坑壁遮挡, 在近光源处, 坑内区域处于阴影区域, 在远光源处坑内区域处于光照范围, 形成光亮区域. 由于灰度对比明显, 阴影区域和光亮区域较容易分割和提取. 传统的识别算法通常分别提取这两个区域的边缘, 然后按照一定规则将它们组合成完整的撞击坑(Cheng等, 2003). ② 撞击坑内部和边缘的灰度沿着光照方向相反. 在光照方向, 撞击坑内部区域的像素灰度值从阴影向光亮区域递增. 相反, 由于不受坑壁遮挡, 撞击坑边缘距离光源越近, 边缘越明亮, 灰度值越高. ③ 当太阳高度角较低时, 光学影像中撞击坑边缘往往被分为三段: 明亮区外边缘、阴影区外边




图 1 撞击坑典型特征

(a)~(c)来自Odyssey THEMIS火星影像(Christensen等, 2003); (d)来自阿波罗10号Moltke撞击坑侧视图; (e)~(h)来自LROC WAC月球影像(Speyerer等, 2011), 四类形貌特征示意图引自岳宗玉等(2023)

缘和明暗区分界线。前两段边缘“形心”连线与光照方向大致平行, 而明暗分界线的方向与光照方向接近垂直。据此特征, 张吴明等(2013)单独提取了撞击坑的明暗分界线与外部边缘, 使用外部边缘线来拟合撞击坑, 同时根据明暗分界线进一步确认候选撞击坑, 从而实现了月球撞击坑的精确探测。

(3) 地形地貌特征。① 根据撞击坑的形貌特征可大致将其分为: 简单撞击坑、复杂撞击坑和多环盆地(Heiken等, 1991)。简单撞击坑形态呈“碗状”, 坑口直径一般较小, 没有开阔的平底和中央峰, 但周边多分布喷射状沉积物。复杂撞击坑直径一般大于15km, 坑口呈锯齿状, 坑内常有中央峰。多环盆地则由大型撞击体产生, 直径通常超过100km, 其特征包括多个同心环状地层、中央隆起地形、向外扩散的射线状地形以及环状断层等。传统的识别算法通常根据地貌特征, 往往分别提取简单撞击坑和复杂撞击坑, 例如, Xie等(2013)寻找DEM(Digital Elevation Model, DEM)局部最小高程值作为简单撞击坑的中心, 而将撞击坑坡度图上中央峰周围平坦地带的质心作为复杂撞击坑的中心。②

撞击坑边缘坡度、曲率往往大于周围区域。基于撞击坑的DEM数据, 可获得高程、坡度、坡向、曲率、地表粗糙度等地形因子。坡度和曲率分别是DEM的一阶与二阶导数, 分别表征地表高程变化和地形起伏的缓急程度。大多数基于DEM数据的撞击坑提取方法(Bue和Stepinski, 2007; 骆磊等, 2014)使用这些地形因子识别撞击坑边缘。③ 撞击坑内高程低于坑外, 坑边缘高程高于周围区域。除了应用规则格网和不规则三角网数据结构表示撞击坑几何结构外, 等高线簇也常用来描述撞击坑, 在等高线簇上体现为高程值内低外高、封闭、环状等特征。据此, 研究人员利用等高线簇(刘宇轩等, 2018)或撞击坑垂直剖面的凹凸性(Yue等, 2013)来识别撞击坑。

3 撞击坑遥感影像数据与矢量编目数据

目前, 借助行星测绘遥感技术, 人类有能力对太阳系中的类地行星、小行星和彗星等天体实现探测, 并获取了较高分辨率的遥感影像数据与地形高程

数据, 并在此基础上生成了DIM(Digital Image Model)、DEM、DTM(Digital Terrain Model)和DOM(Digital Orthophoto Map)等空间数据成果, 为撞击坑的提取以及撞击坑编目数据库的建立奠定了基础。

3.1 撞击坑遥感影像数据

在太阳系的八大行星中, 只有水星、金星、地球和火星是固态天体, 而太阳系内一些行星的卫星以及一些小行星也属于固态天体, 具备形成撞击坑的条件。例如, 月球是地球最近的固态卫星, 而谷神星则是太阳系中体积最大的岩石质小行星。这些固态天体撞击坑的提取与识别主要依赖光学影像数据和数字高程模型(DEM)数据。因此, 本节主要总结了月球、火星、水星、金星和谷神星的主要轨道器遥感数据以及相关的数字衍生产品, 详见表1。

(1) 月球轨道器遥感数据。月球是人类探索地外天体的第一站, 起始于20世纪50年代美苏之间的太空竞赛促使人类探月进入第一个繁盛期, 但由于设备较为落后, 该时期的遥感影像数据存在分辨率较低、覆盖不完整等问题。经过数十年之久的探月沉寂期, 以及第三次科技革命的洗礼, 自20世纪90年代后, 全球对月探测进入第二个繁荣阶段, 欧洲空间局(ESA)、日本、印度、美国、中国等都发射了月球探测器。

欧洲空间局于2003年9月27日成功发射的“智慧一号”(SMART-1)是欧洲空间局第一个月球探测器, 利用其携带的高分辨率摄像机、红外光谱仪、射线光谱仪、激光高度计等载荷, 详细绘制了月球表面地形地貌图和矿物分布图。日本于2007年9月13日成功发射了“月亮女神号”(Kaguya)探测器, 其携带激光高度计与地形相机, 获取了月球表面的高程信息与高分辨率图像, 并在此基础上制成全月DEM(Barker等, 2016)、DIM(Haruyama等, 2009)等数字产品。印度在2008年11月8日发射了“月船一号”(Chandrayaan-1)探测器, 搭载了地形制图相机、高光谱成像仪、激光测高仪等载荷, 在100km的月球轨道上获取了5m分辨率的全月影像; 其后, 在2023年8月23日, “月船三号”(Chandrayaan-3)探测器成功软着陆于月球南极, 印度成为首个在月球南极实现软着陆的国家。美国于1994年1月25日发射了“克莱门汀号”(Clementine)月球探测器, 搭载了紫外-可见光多波段相机、近红外CCD相机、激光成像探测与测距系统和高分辨率相机, 获

取了多波段影像(Isbell等, 1999; Eliason等, 2003; Gaddis等, 2007)与地形数据(Smith等, 1997), 并建立了月球控制网且制作了分辨率为100m/pixel的全月数字正射影像图; 其后, 在2009年6月18日, 美国又发射了“月球勘测轨道飞行器”(LRO), 搭载了激光高度计和月球勘测轨道器相机(LROC), 分别获取了全月地形信息和高分辨率影像(Speyerer等, 2011), 制作了目前精度最高的全月数字高程模型。此后, 美国在2017年进一步推出了名为“阿尔忒弥斯”(Artemis, <https://www.nasa.gov/specials/artemis/>)的重返月球计划, 旨在2025年实现人类再次登陆月球。中国于21世纪初开展的“嫦娥探月工程”, 将人类推向了第二次探月高潮。2007年10月24日发射升空的“嫦娥一号”(CE-1)携带了激光高度计与CCD立体相机, 获取了大量的月球科学数据, 其中包括全月高分辨率正射影像(李春来等, 2010a)、立体影像(李春来等, 2010a)、数字高程模型(李春来等, 2010b)等; 2010年10月1日“嫦娥二号”(CE-2)发射, 其搭载了激光高度计和CCD立体相机等七种载荷, 在100km极轨轨道上获取了空间分辨率7m的全月影像图, 并在15km高度的月球虹湾成像轨道获取了优于1.5m高分辨虹湾地区局部影像; 2013年12月14日“嫦娥三号”(CE-3)探测器成功软着陆在月球雨海西北部, 这标志着中国首次成功执行月球软着陆任务。CE-3探测器由着陆器和巡视器组成, 着陆器携带了月基光学望远镜、极紫外相机、地形地貌相机和降落相机, 而巡视器搭载了全景相机、测月雷达、红外成像光谱仪等科学载荷。2019年1月3日发射的“嫦娥四号”(CE-4)探测器成功着陆在月球背面“冯·卡门撞击坑”内, 实现了人类首次月球背面的软着陆和巡视勘察; 2020年11月24日发射的“嫦娥五号”(CE-5)完成了月球表面自动采样任务并重返地球, 实现了中国月球首次无人采样返回。

(2) 火星轨道器遥感数据。自20世纪60年代起, 全球已开展了40余次火星探测任务, 成功率不足一半(邱凯昌等, 2018)。然而随着科学技术的不断进步, 探测技术逐渐走向成熟, 尤其在20世纪90年代后, 探测任务的成功率显著提高, 其探测手段主要以环绕和巡视探测为主, 其间积累了大量的火星遥感数据, 为人类更深入地了解火星提供了宝贵的信息。

1997年9月12日, 美国国家航空航天局(NASA)成功将“全球勘测者号”(MGS)轨道器送入火星轨道。轨

表 1 20世纪90年代以来部分固态天体的轨道器遥感数据^{a)}

天体	探测器	发射时间	组成/有效载荷	数字产品/分辨率(m)
月球	智慧一号(SMART-1)	2003-09	激光高度计; 高分辨率摄像机	—
	月亮女神号(Kaguya)	2007-09	激光高度计(LALT) 地形相机(TC)	*DEM/59(Barker等, 2016) DIM/10(Haruyama等, 2009)
	月船一号(Chandrayaan-1)	2008-11	激光高度计; 地形制图相机; 高光谱成像仪	—
	月船三号(Chandrayaan-3)	2023-07	轨道器+着陆器+巡视器	—
	克莱门汀号(Clementine)	1994-01	紫外-可见光相机 近红外CCD相机 激光成像探测与测距系统 高分辨率相机	DIM/100(Isbell等, 1999) DIM/100(Gaddis等, 2007) DEM/100(Smith等, 1997) DIM/7~20(Malin和Revine, 1998)
	美国月球勘测轨道飞行器(LRO)	2009-06	月球轨道器激光高度计(LOLA) 月球勘测轨道器相机(LROC)-宽角相机(WAC); 月球勘测轨道器相机(LROC)-窄角相机(NAC)	DEM/59(Barker等, 2016) DIM/100(Speyerer等, 2011) DTM/5(Henriksen等, 2017)
	嫦娥一号(CE-1)	2007-10	CCD立体相机 激光高度计 激光高度计; CCD立体相机	立体影像/120(李春来等, 2010a) DIM/120(李春来等, 2010a) DEM/500(李春来等, 2010b) DTM/192(李春来, 2013)
	嫦娥二号(CE-2)	2010-10	CCD立体相机 激光高度计 激光高度计; CCD立体相机	立体影像/7(刘建军等, 2013) DIM/7(李春来等, 2018) DEM/20(李春来等, 2018) DTM/-(李春来等, 2018)
	嫦娥三号(CE-3)	2012-12	着陆器+巡视器(玉兔一号)	—
	嫦娥四号(CE-4)	2019-01	中继星(鹊桥)+着陆器+巡视器(玉兔二号)	—
	嫦娥五号(CE-5)	2020-11	着陆器(降落相机、全景相机等四类载荷)	—
	火星全球勘测者号(MGS)	1996-11	火星轨道相机(MOC) 火星轨道激光高度计(MOLA)	DIM/256(Caplinger和Malin, 2001) *DEM/200(Ferguson等, 2018)
	火星奥德赛号(MO)	2001-04	热辐射成像仪(THEMIS)	DIM/100(Christensen等, 2003)
	火星快车(MEX)	2003-06	高分辨率立体相机(HRSC) 高光谱探测仪(OMEGA)	DIM/12.5(Gwinner等, 2010) DTM/12.5(Gwinner等, 2010) DIM/1480(Ody等, 2012)
	火星勘测轨道飞行器(MRO)	2005-08	高分辨成像相机(HiRISE) 背景相机(CTX)	DIM/0.25~0.5(McEwen等, 2007) DTM/0.25~0.5(Kirk等, 2008) DIM/0.7
水星	天问一号(Tianwen-1)	2020-07	高分辨率相机 中分辨率相机	着陆区DIM/0.7(Malin等, 2007) 着陆区DEM/3.5 —
	水手10号(Mariner 10)	1973-11	光学相机	DIM/250(Becker等, 2012)
	信使号(Messenger)	2004-08	水星双成像系统(MDIS) 激光高度计(MLA)	DIM/250(Becker等, 2012) —
金星	贝皮可伦坡号(BepiColombo)	2018-10	激光高度计; 热成像光谱仪	—
	水手10号(Mariner 10)	1973-11	光学相机	—
小行星	麦哲伦号(Magellan)	1989-05	合成孔径雷达(SAR)	DIM/75(Ford, 1993) DEM/4641(Ford, 1992)
	会合-舒梅克号 (NEAR Shoemaker) [探测目标: 爱神星]	1996-02	近红外成像光谱仪 多光谱成像仪 激光高度计	—
	黎明号(Dawn) [探测目标: 灶神星和谷神星]	2007-09	光学/红外成像光谱仪 帧式相机(FC)	DIM/35(Roatsch等, 2016) DTM/140(Roatsch等, 2017)

a) 上标“*”表示该数字产品通过数据融合制成. DEM仅仅标注平面空间分辨率. 符号“—”表示相应数据产品不可获取或未公开

道器携带了火星轨道相机(MOC)和火星轨道激光高度计(MOLA)等载荷。获取的MOC宽角相机数据可覆盖火星全球, 分辨率在240m~7.5km; 窄角相机数据仅覆盖火星表面的5.45%, 分辨率在1.5~12m; MOLA测距精度为0.37m。其后, 于2001年4月7日, NASA成功发射了火星“奥德赛号”轨道器(MOO), 并借助其携带的热辐射成像仪(THEMIS), 生成了覆盖全火星的影像数据集(Christensen等, 2003)。THEMIS影像包含5个可见光波段(分辨率为18m)以及10个红外波段(分辨率为100m)。2005年8月12日, NASA进一步发射了火星“勘测轨道飞行器”(MRO), 携带了高分辨成像相机(HiRISE)、背景相机(CTX)和紧凑型火星侦察成像光谱仪(CRISM)等科学仪器。HiRISE影像分辨率高达0.25m, 而CRISM则提供了544个波段的高光谱数据, 分辨率为18m。除了环绕探测外, NASA自20世纪90年代陆续将索杰纳号(Sojourner, 1997年7~9月)、勇气号(Spirit, 2004~2010年)、机遇号(Opportunity, 2004~2018年)、好奇号(Curiosity, 2012年至今)、毅力号(Perseverance, 2021年至今)五部火星车成功送到火星表面, 以获取更为精细的就位探测数据, 用于火星的高精度制图和导航、土壤和岩石生化成分分析、火星大气成分分析, 以及寻找生命迹象等火星科学研究。

除美国外, 欧洲空间局(ESA)于2003年12月25日将“火星快车号”(MEX)探测器送往火星轨道。该探测器搭载了高分辨率立体相机(HRSC)和高光谱探测器(OMEGA)等载荷。HRSC获取了火星表面可见光和近红外9个波段的影像数据, 分辨率达到10m, 而OMEGA获取了火星表面352个波段的光谱信息。此外, 中国于2020年7月23日成功发射了“天问一号”(Tianwen-1)探测器, 次年5月15日, 其携带的“祝融号”(Zhurong)火星车成功着陆在乌托邦平原南部预选着陆区, 标志着中国成为继美国之后世界上第二个在火星着陆的国家。“天问一号”轨道器配置了高分辨率相机、中分辨率相机、次表层探测雷达等7台科学有效载荷, 而“祝融号”巡视器搭载了多光谱相机、地形相机, 次表层探测雷达等6类有效载荷。

(3) 水星轨道器遥感数据。美国NASA于1973年11月3日发射的“水手10号”(Mariner 10)是第一个探测水星的轨道器, 其搭载了两架配备照相机的望远镜、红外辐射计、紫外掩星光分仪等7种传感器, 用于研究行星的形貌、大气和磁场等。该探测器同时飞越水星

和金星两颗行星, 在通过飞掠方式探测完金星后, 借助金星的引力改变轨道, 进入了环日飞行轨道, 然后三次飞掠水星, 获取了超过2,700张影像, 记录了几乎一半的水星地表。这些图像揭示了水星表面充满环形山的斑驳地貌以及小至100m的形貌细节。此后, NASA于2004年8月3日成功发射了“信使号”(Messenger)水星探测器, 于2011年3月18日进入水星轨道, 该探测器搭载了水星双重成像系统(MDIS)和激光高度计(MLA)等设备。基于“水手10号”与“信使号”获取的数据, Becker等(2012)制作了水星全球DIM数据。“贝皮可伦坡号”(BepiColombo)是欧洲空间局和日本合作开发的探测器, 于2018年10月20日发射, 其计划进行两次金星飞掠和六次水星飞掠, 最终将于2025年进入环绕水星的轨道。“贝皮可伦坡号”搭载了激光高度计、水星辐射计和热红外光谱仪等十几种科学仪器, 用于研究水星的地质、大气和磁场等特征。

(4) 金星轨道器遥感数据。由于金星表面常年被硫酸颗粒组成的厚云层所覆盖, 对金星的探测重点集中在大气探测上, 而对地表的探测较少。譬如, “水手10号”在1974年两次飞掠金星, 获取了4165张金星外层大气层的图像。人类首次利用行星测绘遥感技术系统地探索金星地表可以追溯到1989年5月, 美国“麦哲伦号”(Magellan)探测器使用合成孔径雷达(SAR)技术对金星表面进行了高分辨率的雷达成像, 在此基础之上制作并发布了多种数字产品, 包括DIM(Ford, 1993)和DEM(Ford, 1992)。2005年11月9日, 欧洲空间局发射“金星快车号”(VEX)探测器, 使用红外成像、紫外成像和雷达测高技术探测金星的大气和地表。

(5) 小行星轨道器遥感数据。小行星承载太阳系早期起源和演化的重要信息, 是研究太阳起源的活化石(张荣桥等, 2019)。小行星探测历程经历了多个阶段, 从最初的近距离飞掠探测, 如“伽利略号”(Galileo)、“深空1号”(Deep Space 1)、“露西号”(Lucy), 到绕飞探测, 如“黎明号”(Dawn)、“会合-舒梅克号”(NEAR Shoemaker), 再到就位探测和采样返回, 如“隼鸟1号”(Hayabusa 1)、“隼鸟2号”(Hayabusa 2)、“欧西里斯号”(OSIRIS-REx)。其中在绕飞探测方面, “会合-舒梅克号”于2000年2月14日进入“爱神星”轨道, 进行了为期一年的低轨绕飞探测, 其间传回了约1.6万张影像。“黎明号”探测器于2007年9月27日发射成功, 探索小行星带内最大的两颗原行星, 即灶神星与谷神星。

该探测器首先对灶神星进行了为期14个月的探测, 随后进入谷神星轨道, 进行了为期四年的全方位的遥感观测. 通过其搭载的帧式相机(FC)从高低两个轨道分别获取了分辨率为140m/pixel和35m/pixel的影像, 并制作了DTM(Roatsch等, 2017)和DIM(Roatsch等, 2016)数字产品.

3.2 撞击坑矢量编目数据

借助多源遥感影像数据与智能识别算法, 人类已经具备了编制直径大于1km的固态天体撞击坑的能力. 表2列出了月球、火星、金星和谷神星撞击坑矢量编目数据, 其中主要包括撞击坑的坐标和直径等关键信息. 此外, 相关工作(Barlow等, 2012; Yang等, 2020; Wang等, 2021)中发布的月球撞击坑目录、Robbins和Hynek(2012)发布的火星撞击坑目录以及Gou等(2018)和Zeilinhofer和Barlow(2021)发布的谷神星撞击坑目录还包括有关撞击坑深度等额外属性信息. 这些矢量编目数据集为研究固态天体撞击坑的分布、相对定年、精细制图等任务提供了坚实的数据基础. 这些矢量编目数据集在适当转化后, 可作为卷积神经网络的训练数据集, 用于训练深度学习模型. 同时, 矢量编目数据

还可用作真值数据, 为各类撞击坑识别算法的定量比较提供可靠的基准.

4 撞击坑识别方法

本文将当前的撞击坑识别方法分为三类, 即传统撞击坑识别方法、基于机器学习的撞击坑识别方法和基于深度学习的撞击坑识别方法(见图2). 传统撞击坑识别方法往往根据撞击坑呈现出的直接特征, 如梯度、明暗、坡度等, 借助先验规则和非监督算法来识别撞击坑. 由于数据的类型(模态)不同, 撞击坑的特征往往差异很大, 据此, 传统撞击坑识别方法可进一步细分为基于光学影像特征的方法、基于地形地貌特征的方法和融合影像与地形地貌特征的方法. 基于机器学习的撞击坑识别方法利用手动设计的高维度撞击坑隐式特征来训练不同的分类器, 以识别潜在的撞击坑. 因此, 该类方法更强调手动特征的设计和所使用的分类器, 并进一步细分为基于支持向量机、决策树、集成学习(如随机森林和自适应增强AdaBoost)、神经网络四类方法. 近年来, 行星影像和撞击坑目录数据急速增长, 深度学习方法更能适应大数据量且复杂撞击

表 2 部分固态天体撞击坑矢量编目数据

区域	来源	发布年份	相关影像数据	撞击坑数量	撞击坑直径(km)
月球	Head III等(2010)	2010	LOLA DTM	5,158	≥20
	Barlow等(2012)	2012	LOLA DEM; LROC WAC DIM; LROC NAC DTM	12,565	≥5
	Wang等(2015)	2015	CE-1 CCD DIM	105,016	≥0.5
	Krüger等(2018)	2018	SELENE DEM; LROC WAC DIM	5,505	≥3
	Povilaitis等(2018)	2018	LROC WAC DIM	22,746	5~20
	Robbins (2019, 2019)	2018	SELENE TC DIM; LROC WAC DIM; LOLA-SELENE DTM	>2.03×10 ⁶	≥1
	Wang等(2021)	2020	LOLA DEM; Robbins等编目数据库2019	>1.32×10 ⁶	≥1
	Yang等(2020)	2020	CE-1&CE-2 CCD DIM	117,240	≥1
火星	Stepinski等(2009)	2009	MOLA DEM	75,919	≥3
	Salamunićar等(2011)	2011	MOLA DEM	85,783	≥2
	Robbins和Hynek(2012)	2012	THEMIS DIM	384,343	≥1
	Wu B等(2022)	2022	天问一号着陆区DIM	41,034	≥0.8
金星	Herrick和Phillips(1994)	1994	Dawn SAR DIM	1,242	≥2.8
谷神星	Gou等(2018)	2017	Magellan LAMO DIM; Magellan HAMO DTM	29,219	≥1
	Zeilinhofer和Barlow(2021)	2021	Magellan LAMO DIM; Magellan HAMO DTM	44,594	≥1

特征坑的深度挖掘。基于深度学习的撞击坑识别方法大多以深度卷积神经网络为基础,在底层特征表征和编码上差别不大,而更注重在何种尺度上(如图像尺度、目标尺度和像素尺度)来挖掘撞击坑特征,这三种尺度恰恰分别对应图像分类、目标检测和语义分割三类计算机视觉任务。

4.1 传统撞击坑识别方法

4.1.1 基于光学影像特征的方法

基于光学影像特征的方法以光学影像为数据源,依靠影像中的光照对比特征、纹理特征、光谱特征等来识别行星撞击坑。在太阳高度角较低、光照对比度显著,许多学者(Cheng等, 2003; Sawabe等, 2005, 2006; 冯军华等, 2010; 张吴明等, 2013)开展了阴影区域和光照区域的撞击坑提取工作。当太阳高度角较高时,撞击坑的光照对比度不明显,此时,研究人员常常采用梯度结构张量(Leroy等, 2001; Ding等, 2008; Emami等, 2019)、灰度共生矩阵(Kim等, 2005)、统计分析(Barata等, 2004)等纹理特征分析方法来识别撞击坑的边缘。此外, Sawabe等(2006)甚至利用了紫外-可见光波段的多光谱数据来辅助识别月球撞击坑。

众多学者主要从“数据驱动”和“模型驱动”两个维度展开基于光学影像特征的撞击坑识别。其中,“数据驱动”的方法依赖影像中提取的撞击坑边缘特征来拟合撞击坑,其核心流程包括影像特征增强、边缘提取、撞击坑阴影与光照区域划分、撞击坑阴影边缘与光照边缘配对、边缘细化与连接、圆/椭圆拟合等步骤。例如, Cheng等(2003)改进了Canny边缘检测算法(Canny, 1986),使用两种大小的Canny算子卷积核来检测不同尺寸和边缘显著性的撞击坑边缘。然后,结合光照方向与撞击坑边缘锚点信息,划分撞击坑边缘为明亮与阴影两类,并根据边缘长度、边缘锚点距离、边缘间剖线的单调性进行配对,组成撞击坑的完整边缘,并进行椭圆拟合。最后,基于目标优化方法,最小化撞击坑边缘像素法向与光照方向间的夹角,调整椭圆位置和参数,实现亚像素级别的拟合精度。Sawabe等(2006)提出一种基于模糊霍夫变换的撞击坑识别方法。该算法首先根据光照方向的撞击坑灰度分布具有单调性的特点,将影像分为明暗两部分区域,并使用基于边缘强度(Sugiyama和Abe, 1997)的最大似然阈值法(Kurita等, 1992)提取两个区域内的撞击坑边缘。

随后,对这些边缘进行细化和连接,并借助模糊霍夫变换进一步提取撞击坑。该方法在包括月球危海等多个测试区域内识别了超过80%的撞击坑,但在高太阳高度角影像上的识别效果不佳。冯军华等(2010)针对深空探测器行星地标视觉导航任务,提出了一种撞击坑识别与匹配方法。该方法通过分析陨石坑阴影区边缘和光照区边缘的凹凸方向以及边缘之间的方位与尺寸关系,对陨石坑明暗区域内的边缘进行配对,并采用最小二乘法拟合陨石坑的椭圆参数。张吴明等(2013)针对低太阳高度角的光学影像提出了一种新的撞击坑识别算法。该方法的步骤包括Winner滤波去噪、自适应阈值的Canny边缘检测(Canny, 1986)、基于边缘灰度分布的陨石坑边缘连接、撞击坑边缘线识别和配对等流程,并采用最小二乘圆拟合撞击坑。其中,边缘连接充分利用坑内外灰度变化方向与光照方向之间的分布规律,将外部边缘和内部明暗分界线归为两类进行提取。撞击坑边缘线的识别主要从单条边缘、边缘线组合和整个撞击坑三个尺度筛选边缘,并进行圆拟合,达到了73.9%的月球撞击坑识别率。然而,该方法所施加的判别准则约束较严格,对复杂撞击坑的识别能力较弱。

当光照对比度不显著时,“数据驱动”的方法主要依靠影像的纹理特征来识别撞击坑。例如, Kim等(2005)基于灰度共生矩阵分析图像纹理提取感兴趣撞击坑边缘特征,并使用无向图组织提取的边界段,将陨石坑探测问题转化为从无向图中迭代搜寻封闭子环问题。Ding等(2008)利用KLT算法(Tissainayagam和Suter, 2004)提取月球影像像素点的结构张量,分析光学影像中纹理变化剧烈区域,实现撞击坑目标区域的粗定位。然后,结合“数据驱动”方法的一般流程,对定位区域内的撞击坑进行精确提取。Leroy等(2001)则将结构张量用于精确估算候选撞击坑边缘点的曲率,从含有大量噪声的边缘图像中提纯撞击坑。Besse等(2012)在高通、拉普拉斯和MadMax(Koutchmy等, 1988)三种滤波算法的结果上拟合椭圆,从低分辨率、光照条件欠佳的小行星影像中提取撞击坑。Barata等(2004)利用统计分析从MOC火星影像中分别得到均值、极差、方差、熵、偏度图像,并对其进行形态学操作与二值化,以去除噪声并增强边缘。

“模型驱动”的撞击坑识别方法则是在边缘特征提取基础之上,采用模板匹配技术,在迭代过程中按照由

小到大的顺序识别影像中不同尺寸的撞击坑。目前主流的匹配方法有方差匹配、相关性匹配、相关系数匹配、傅里叶变换匹配等。例如, Barata等(2004)在利用“统计分析”增强影像形态学纹理基础之上, 进一步利用相关性匹配法识别撞击坑。Kim等(2005)则仅将“模板匹配”应用于拟合撞击坑的结果验证阶段, 通过相关性匹配法进一步提高了撞击坑的识别精度。Bandeira等(2007)将不同尺寸的二值模板应用到火星边缘二值图中, 并使用快速傅里叶变换(Fast Fourier Transform, FFT)匹配模板与二值图像中潜在的撞击坑。该方法对半径大于5个像素的撞击坑识别效果较好, 达到了86.57%识别率和15.95%错检率。Pedrosa等(2017)同样采用“模板+FFT”匹配方法, 在火星影像中实现了92.23%的撞击坑探测率。综上可知, “模型驱动”方法更强调匹配的一致性, 而“数据驱动”方法更强调拟合的精确性。

光学影像撞击坑的提取方法严重依赖太阳高度角和人为预定义的提取规则。尽管基于纹理分析的方法可以在一定程度上缓解光照对比度不强的缺陷, 但由于影像分辨率、撞击坑模糊和破碎边缘形态等限制, 利用传统方法从光学影像中精确识别撞击坑仍然具有挑战性。另外, 由于光学影像缺乏深度信息, 行星表面的近圆形山丘、沙丘等地貌也容易被误识别为撞击坑。基于撞击坑多数为圆或椭圆的先验假设, 当前撞击坑的拟合方法主要基于“霍夫变换”或“随机采样一致性”算法及其变种, 这导致识别的撞击坑边缘仅是“拟合边缘”, 而非精确的“物理边缘”, 这在很大程度上限制了对撞击坑形态的精确分析和深度应用。

4.1.2 基于地形地貌特征的方法

该方法主要基于数字地形分析, 通过引入DEM中的地形地貌因子, 并应用传统影像撞击坑识别方法, 以精确识别撞击坑。常见的地形地貌因子包括坡度、坡向、曲率、地貌晕渲、地形起伏度以及垂直剖面的曲率、深度和凹凸等。撞击坑在DEM和相应的特征图上往往表现出如下特征: 撞击坑的中心是局部最低点, 边缘是局部最高点; 撞击区域的高程明显低于周边区域, 并形成封闭的盆地结构; 撞击坑等高线往往呈现嵌套的类圆环状; 撞击坑的垂直剖面线通常显示局部的下凹特征; 复杂撞击坑中央峰附近的环状区域平坦且对称。基于上述特征, 利用DEM地形地貌特征图进行数

字地形分析, 可以精确判别撞击坑。

众多学者开展了广泛的研究来提取撞击坑地形地貌因子。例如, Yue等(2013)利用嫦娥一号的DEM数据提取等高线, 并通过圆度、形态比和矩形度等形状参数, 排除伪撞击坑。最后, 基于DEM的剖面特征来综合识别撞击坑。骆磊等(2014)将坡度图与曲率图相乘, 得到新的地形特征图, 用于提取嫦娥一号DEM撞击坑。该方法有效保留撞击坑边缘信息, 同时弱化虚假信息对撞击坑识别的干扰, 具有较高的识别精度。刘宇轩等(2018)利用撞击坑等高线呈相互嵌套的类圆环状特点, 从单线形态、多线间关系、剖面凹凸性三个方面筛选撞击坑等高线, 然后基于等高线特征精确提取月球撞击坑。许多学者(Kang等, 2015; Liu等, 2017; Wang和Wu, 2019; Wang等, 2022)通过描述DEM撞击坑纵向剖线的几何结构, 进行撞击坑的识别。一般而言, 坡度能够更好地区分坑壁、坑唇和周边区域, 水平曲率能够更好地刻画撞击坑边缘轮廓的凹凸性, 垂直曲率可以更好地描述撞击坑垂直切割剖面/边缘的凹凸性等。这些特征往往以互补的方式共同刻画撞击坑的形态特征。

尽管相对于图像而言, 从地形地貌三维数据中探测撞击坑更为容易(Bue和Stepinski, 2007), 但对于一些复杂的撞击坑, 如嵌套撞击坑、连体撞击坑、中央峰撞击坑、中央环撞击坑、撞击盆地等, 仍然难以精确提取。为了识别此类复杂撞击坑, 往往将复杂撞击坑和简单撞击坑分开识别(Xie等, 2013; Liu等, 2017), 以及采用淹没算法(O'Callaghan和Mark, 1984)和洼地填充算法(Yue等, 2013)来分离邻接撞击坑和部分重叠撞击坑(Bue和Stepinski, 2007; Yue等, 2013)。例如, Xie等(2013)将简单撞击坑与中央峰复杂撞击坑分开进行识别。对于简单撞击坑, 该方法通过局部最小高程值确定圆心位置, 并使用基于圆心逐渐向外扩张的策略, 寻找径向上局部高程值最大的像素点, 作为坑边缘像素点。对于复杂撞击坑, 该方法首先在坡度图上采用洼地填充算法, 计算坑内中央峰周围的环状平坦区, 并将该区域的质心作为撞击坑的中心点, 然后对坡度图进行二值化, 并去除中央峰区域, 得到坑壁的边缘。最后, 该方法使用最小二乘拟合圆形撞击坑。Liu等(2017)结合分水岭方法和撞击坑的垂直剖面分析, 将撞击坑分为独立撞击坑与附近的次生撞击坑, 然后进行分类识别, 其准确率最高可达77.8%。该方法能够为现有撞

击坑编目数据库提供不规则的真实边缘信息, 但无法提取重叠撞击坑。针对重叠撞击坑, Yue等(2013)首先使用洼地填充算法将这些撞击坑进行分离, 然后分别进行特征识别。在月球三个小型测试区(北半球高地、北半球月海和南半球高地)进行实验, 该方法的识别率几乎达到100%。然而, 该方法仅能对潜在的撞击坑进行探测, 不能准确分割撞击坑的边界。类似地, Bue和Stepinski(2007)利用淹没算法对DEM中的连续低地进行分割, 并在分割后的低地标注上包围框。然后对包围框内的DEM进行计算, 并生成曲率图, 最后使用圆形霍夫变换来提取曲率图中撞击坑的圆心和半径。该方法不考虑退化严重的撞击坑的情况下, 识别率达到92%。该方法成功识别出了许多编目数据库以外的小型撞击坑, 但对于退化撞击坑识别效果较差。淹没算法一方面提升了撞击坑的可分离性, 另一方面可以实现对撞击坑感兴趣区域的粗略定位。通过采用粗细两种粒度相结合的识别策略, 极大地提升了撞击坑识别效率。

基于地形地貌的方法虽然精确, 但是地形因子分析的准确度严重依赖于DEM的水平分辨率与垂直精度。基于DEM的地形地貌检测方法仍然面临遗漏浅撞击坑、小尺寸撞击坑和退化撞击坑的问题。

4.1.3 融合影像与地形地貌特征的方法

该方法充分利用光学影像和DEM数据的互补性, 融合影像数据的颜色、纹理、强度等形态信息, 以及DEM数据的坡度、坡向、垂直剖面等信息综合识别撞击坑。融合模式可大概分为使用方式上的串行融合、数据通道上的并行融合, 以及特征、算法和结果尺度上的融合等。

在串行融合方面, 罗中飞等(2014)融合嫦娥一号光学影像数据与DEM数据实现月球撞击坑自动提取。首先利用光学影像中的撞击坑光照特征, 结合阈值分割、区域生长算法和最小二乘拟合, 初步识别撞击坑。然后通过DEM数据计算撞击坑坑壁的坡向连续性, 剔除影像中错误提取的撞击坑, 并根据撞击坑坑底面积占比、剖面线特征, 将撞击坑分为简单型、复杂平底型和复杂中央隆起型。该方法实现了“光学影像粗提取+DEM数据核验”的串行融合模式。同样基于该融合模式, Kang等(2015)融合嫦娥一、二号影像与对应的DEM数据, 成功识别月球表面撞击坑, 并将撞击坑分

为简单撞击坑、中央隆起型和中央平底型复杂撞击坑, 但未能正确识别更复杂的单环或多环撞击坑盆地。Wang和Wu(2019)进一步将“光学影像粗提取+DEM数据核验”模式引入机器学习的自主训练机制中, 在迭代训练中识别撞击坑的正负样本, 并将这两类样本反馈至月球撞击坑训练样本数据集。这种动态训练过程扩充了手工标注样本数据集, 提升了机器学习模型训练的稳定性。

在数据通道上的并行融合方面, Jia等(2021b)将嫦娥一号影像和DEM数据在数据通道尺度上进行融合, 然后通过卷积神经网络识别月球撞击坑。类似地, Tewari等(2022)也在通道尺度上融合DEM、光学影像和坡度图等数据, 将融合后的多通道数据输入Mask-RCNN网络, 预测月球撞击坑。Yang和Kang(2019)通过在贝叶斯框架下将遥感影像中提取的“方向梯度直方图特征”和DEM数据中提取的“多尺度坡度和坡向直方图特征”进行高层次的特征尺度融合, 取得了84.8%的月球撞击坑识别精度。Hsu等(2021)提出的撞击坑目标检测模型将原始遥感影像与圆形霍夫变换后的结果图像分别输入FPN(Feature Pyramid Networks)特征提取网络, 最后将对应的特征图相加, 实现了基于特征维的融合。圆形霍夫变换后的图像为深度学习模型提供了撞击坑几何形状先验, 提升了约2%的撞击坑识别率。

多源数据融合虽然可以提升撞击坑识别率, 但对多模态数据源易获取性要求较高。同时, 多模态数据也意味着更高的成本和更复杂的处理方法。设计融合算法往往需要考虑“如何融合以及在何种尺度和粒度上进行数据融合既能发挥他们的互补性, 同时又能避免各自数据固有的缺陷”这个核心问题。其中, 包含多模态数据配准、多模态数据之间的尺度一致性和时空一致性处理等关键问题。

4.2 基于机器学习的撞击坑识别方法

本文提及的“机器学习”仅指浅层机器学习(Janiesch等, 2021), 以区别4.3节所述的“深度学习”。其主要包含随机森林(Random Forest, RF)、自适应增强(Adaptive Boosting, AdaBoost)、决策树(Decision Tree, DT)、支持向量机(Support Vector Machine, SVM)、遗传算法(Genetic Algorithm, GA)和人工神经网络(Artificial Neural Network, ANN)等模型及相关变种。

传统的撞击坑识别算法是基于人工设定的规则, 通过建立撞击坑识别特征与撞击坑先验模型之间的数学关系进行识别. 然而, 这种方法容易受到数据质量、判别规则和先验假设模型等因素的影响. 特别是对于特征不明显的退化撞击坑和复杂撞击坑, 传统算法识别能力较差, 其泛化和迁移能力也相对较弱. 相比之下, 机器学习方法通过对特征的深入编码和大量撞击坑样本的训练和学习, 试图在高维空间中描述撞击坑特征间的分布模式和复杂的非线性关系, 从而实现对撞击坑识别及子类制图. 尽管传统的无监督撞击坑探测方法在自动化程度方面具有一定优势, 但其探测精度通常比机器学习方法低一个数量级(Ding等, 2011).

机器学习在撞击坑预测方面的准确性主要受到三个方面因素的限制, 包括训练样本、特征编码和分类器. 机器学习需要大规模高质量的训练样本来进行模型训练. 训练样本的数量越多, 模型过拟合的风险就越小. 在行星科学领域, 制作撞击坑训练样本通常需要专家进行人工标注, 或者转化撞击坑编目数据库来生成训练样本. 然而, 这个过程通常费时费力, 并且无法保证标注样本的代表性, 特别是对于负类非撞击坑样本的手工标注(Martins等, 2009). 为了克服这个问题, 往往采用数据增强(Emami等, 2019)、自主学习(Wang和Wu, 2019)和迁移学习(Ding等, 2011)等策略, 以解决机器学习领域中训练样本不充分以及类地行星间的跨域学习和预测等问题.

特征编码包含特征构建和特征选择, 构建具有紧凑性和区分度的特征直接决定了撞击坑预测的精度. 例如, 丁萌等(2009)使用Census变换将原始图像转化为灰度直方图特征向量, 并用于编码训练样本图像, 最终输入SVM分类器来检测月球表面的撞击坑. Urbach等(Urbach和Stepinski, 2009)采用“胡氏不变矩”的7个矩不变量(Hu, 1962)编码传统方法生成的候选撞击坑, 用于训练C4.5决策树模型, 实现对候选撞击坑的进一步筛选. AutoCrat系统(Stepinski等, 2009)通过用户定义的规则从火星DEM数据中提取候选撞击坑, 并利用深度、直径和形状特征训练C4.5决策树模型, 将候选撞击坑分为正负两类. Liu Q等(2019)采用描述撞击坑的几何形状、深度和密度等32个特征编码月球DEM样本数据集, 并利用RF分类器区分“主撞击坑”及“次生撞击坑”. Wang等(2022)使用撞击坑“径向剖面”编码月球DEM撞击坑, 并利用RF筛选候选撞击坑. 类似地, 撞

击坑“纵向剖面线”特征也被用来训练SVM分类器, 以验证AdaBoost预测的初始撞击坑的分类结果(Wang和Wu, 2019). “类哈尔”特征(Viola和Jones, 2001)也常被学者(Martins等, 2009; Ding等, 2011; Wang和Wu, 2019)用于描述撞击坑的特征纹理, 构建撞击坑特征向量来训练分类器. Emami等(2017)将计算机视觉中常用的8个特征描述子用来描述撞击坑特征, 并通过对比实验发现HoG特征(Dalal和Triggs, 2005)取得了最高验证和测试精度. 此外, 浅层的卷积神经网络(Cohen等, 2016; Emami等, 2015)也常被用来提取撞击坑特征, 描述卷积核内像素间的非线性关系. 尽管这些特征在机器学习训练中提升了撞击坑的识别精度, 但可能存在一些冗余特征. 因此, 需要进行特征筛选, 以增强特征对撞击坑的表达能力, 并提升训练效率. 例如, 丁萌等(2009)利用主成分分析(Principal Component Analysis, PCA), 将原始撞击坑灰度直方图特征压缩至26维特征向量. 其他许多学者则利用DT(Stepinski等, 2009; Urbach和Stepinski, 2009)、RF和AdaBoost等集成学习(Ensemble Learning, EL)模型(Martins等, 2009; Ding等, 2011; Wang和Wu, 2019; Liu Q等, 2019; Wang等, 2022)在训练过程中同时实现撞击坑的特征显著性选择和识别.

在分类器方面, RF和AdaBoost都属于集成学习方法, 即训练一系列弱分类器, 然后将它们组合成强分类器. RF能够学习和描述撞击坑的复杂结构, 减少过拟合风险, 并具有一定抗噪声能力和适应不平衡样本能力, 这使得它具备识别小尺寸次生撞击坑(Liu Q等, 2019)的能力. AdaBoost与RF分类器具有类似的分类精度(Chan和Paelinckx, 2008), 但对异常样本敏感, 在迭代过程中, 异常样本往往被赋予较高的权重, 从而影响最终“强分类器”预测的准确性. 因此, 利用AdaBoost开展撞击坑分类任务时, 要保证撞击坑训练样本的可靠性和准确性. DT模型易于理解和解释, 能够捕捉输入撞击坑特征间的非线性关系, 能够实现对撞击坑精细类别制图, 但对噪声敏感, 容易过拟合, 泛化能力较差. SVM在小样本撞击坑训练时表现较好, 但在训练大规模高维度的撞击坑训练数据集时, 适用性较差. GA算法具有全局寻优能力, 其成功应用取决于正确构建契合撞击坑分类任务的“适应度函数”. 然而, 在某些复杂高维度的撞击坑分类场景中, 建模过程往往十分困难. ANN能够学习和表示撞击坑边缘相邻像素间复

杂的非线性关系,但在处理小规模数据时易过拟合。

机器学习在撞击坑识别中具有较高的精度,这是因为在数据集制作、特征构建和分类预测三个阶段同时考虑了撞击坑多尺度特征,从而赋予机器学习识别不同尺寸撞击坑的能力。具体而言,在撞击坑探测中,机器学习采用了两种模式,即“直接探测模式”和“间接验证模式”,这两种模式均考虑了尺度效应。“直接探测模式”是指从原始撞击坑影像中直接利用机器学习识别潜在的不同尺寸撞击坑。在该模式下,通过构建多尺度金字塔,解决特征表达的尺度不变性和预测的自适应性等关键问题,从而提高了机器学习的识别精度。“间接验证模式”则是首先使用传统方法得到“候选撞击坑”,然后利用机器学习对其进行进一步验证。由于该模式下机器学习是基于不同尺寸的候选撞击坑进行验证的,因此已经隐式地考虑了撞击坑的多尺度问题。

4.3 基于深度学习的撞击坑识别方法

传统撞击坑识别方法依赖于预定义的判别准则,而监督机器学习方法需在对象尺度上提供具有强区分度和表征能力的特征。这使得上述两类方法在识别撞击坑时严重依赖先验规则的设定、特征的表征能力、输入数据的质量、待识别撞击坑的复杂程度以及训练区域的选择等因素。深度学习模型利用大规模训练集和深层神经网络自动表征撞击坑特征,不仅能够提取更高层、表征能力更强的撞击坑特征,还能够将特征编码、选择和识别有机地结合在一起,具有强大的学习、预测和泛化能力。卷积神经网络(Convolutional Neural Networks, CNN)是深度学习在图像处理领域内最成功的一类模型,能够根据任务需求输出撞击坑的分类、分割或目标检测结果。根据网络模型输出目标的尺度不同, CNN模型可分为图像分类模型、目标检测模型和语义分割模型三类,分别预测输入图像内包含撞击坑的概率、目标框包含撞击坑的概率以及分割像素属于撞击坑的概率。

图像分类网络产生于深度学习的早期阶段,它是从传统方法和机器学习方法向深度学习方法转变的过渡形态。分类网络存在两种识别撞击坑的应用模式:“直接分类模式”(Emami等, 2018a)和“间接验证模式”(Emami等, 2015, 2019)。“直接分类模式”是指直接从原始图像中选择撞击坑训练样本进行训练。在预测阶段,只需要利用不同尺寸的滑动窗口从测试数据集

中裁剪相应尺寸大小的图像并进行尺寸归一化后输入至分类网络进行预测。最后,将汇总不同尺度撞击坑作为最终预测结果。该过程省略了机器学习中繁琐的特征编码步骤。“间接验证模式”是利用分类网络对传统方法或机器学习方法得到的候选撞击坑来进一步验证。在这种情况下,需要根据候选撞击坑对应的原始图像或编码特征来训练和测试分类网络,以提纯候选撞击坑。

“间接验证模式”仍然受限于不充分的特征提取与先验规则,而“直接分类模式”在遍历整幅图像进行预测时,仅能判断是否包含撞击坑,无法直接输出撞击坑的属性信息,如撞击坑的圆心、半径、类别等。为解决此问题,往往先使用一个网络模型判断“滑动窗口”是否包含目标,并保留置信度较高的窗口作为候选框,然后用另外一个分类网络进一步回归候选框内目标的属性。这种分两个步骤识别图像中目标的网络模型称为“双阶段”目标检测模型。Faster R-CNN(Ren等, 2015)是识别效果最好的“双阶段”目标检测模型之一。众多学者(Li等, 2017; Wang等, 2018; Emami等, 2018b; Zang等, 2021; Doppenberg, 2021)基于撞击坑探测任务改进Faster R-CNN,实现了撞击坑探测。在候选框提取阶段, Emami等(2018b)将撞击坑检测模型中的检测框长宽比固定为1,减少了计算量,适合在无投影形变时检测近圆形的撞击坑。当投影形变较大时,撞击坑呈现椭圆形, Doppenberg(2021)提出使用Ellipse R-CNN(Dong等, 2021)提取撞击坑,该模型可在第一阶段回归得到包含目标的椭圆参数。针对撞击坑尺寸差异较大的问题, Wang等(2018)提出的CraterIDNet根据标签中的撞击坑尺寸-频率分布,在模型的第一阶段优化了识别目标框的尺寸和密度,该方法在HRSC测试数据集上识别率可超95%,但需要根据训练集和标签的数据分布人工调参,训练步骤较为繁琐。训练标签数据不足常导致目标检测模型在第二阶段预测不准确,为应对此问题, Li等(2017)使用地球上的撞击坑影像对训练集进行扩充,增强了Faster R-CNN模型的泛化性能。Zang等(2021)则将Faster R-CNN(Ren等, 2015)与半监督机制结合,使用少量带标签数据集训练得到两个“教师模型”,并使用这两个模型分别对未标注的数据进行预测,将两次预测结果中置信度都大于0.75的目标保存为新标签,该方法在嫦娥二号影像中月陆(Highland)和月海(Maria)区域分别取得了91.4%和

88.5%的准确率。

然而,“双阶段”目标检测模型仍存在计算量大,无法实现实时检测的问题。为此,Redmon等(2016)将输入图像下采样至 7×7 大小,最后对每个单元格回归计算,输出单元格内目标检测框的中心位置、大小、包含目标的概率和其他属性。这种只用一级网络就能从完整图像中识别目标的模型被称为“单阶段目标检测模型”。这类模型大幅提升了检测效率,因此,大量的研究工作(Li等, 2022; Chatterjee等, 2023; La Grassa等, 2023; Zhu等, 2023)基于经典的单阶段YOLO系列目标检测模型(Redmon等, 2016; Redmon和Farhadi, 2017; Wang等, 2023)识别撞击坑。其中,Chatterjee等(2023)使用自适应阈值的方法增强训练数据集,并使用YOLOv5在CTX影像和HRSC影像中实现了小区域且近实时的撞击坑探测。Zhu等(2023)则利用YOLOv7实现了对LROC WAC影像和LOLA DEM数据的撞击坑探测。与直接套用YOLO系列模型不同, Lee等(2020)针对着陆器导航任务,在YOLO9000的基础上构建出可直接输出撞击坑圆心和半径的检测网络LunarNet。La Grassa等(2023)则在YOLOv5的主干前增添了包含RDB(Residual Dense Blocks)机制的RLNet(La Grassa等, 2022),增强了对影像细节特征的提取,该模型在LROC数据集上的识别率达到了87.2%。基于深度学习的单阶段模型实现了近实时的撞击坑检测,并广泛应用于导航任务中。

虽然目标检测模型能够根据检测框的中心坐标与内切圆直径,快速计算出撞击坑的坐标和半径,但相对固定的检测框形状限制了对撞击坑边缘的高精度拟合。相比之下,语义分割模型能够提取整个撞击坑的边缘像素,与传统边缘提取方法相比,伪边缘较少且准确度更高。在语义分割模型中,U-Net模型(Ronneberger等, 2015)通过多级下采样和上采样机制,可以处理不同尺度的撞击坑。另外,U-Net还通过跳跃连接机制,将细节信息加入到上采样阶段的特征图中,以充分提取撞击坑的边缘特征,因此,U-Net广泛应用于撞击坑探测。相关研究(Lee, 2019; Silburt等, 2019)表明,U-Net可用于多源影像的撞击坑提取。例如,Silburt等(2019)首次将U-Net用于撞击坑分割,先使用仅有三次下/上采样的U-Net模型对月球影像进行初步分割,再利用模板匹配算法实现撞击坑的自动识别与标注,在LRO Kuguya月球DEM数据集上成功提取出92%的撞击坑。

Lee(2019)在由MOLA和HROC联合生成的DTM数据集上,使用经典U-Net模型与模板匹配算法提取撞击坑。

大量的U-Net模型的变种也成功应用于撞击坑识别。这些变种模型通过调整网络模型的下/上采样次数、卷积核数量等模型结构参数,实现模型轻量化,从而提高训练效率(DeLatte等, 2019; Chen等, 2023)。其中,DeLatte等(2019)沿用了“U-Net+模板匹配”的模式,提出了轻量化的语义分割模型Crater U-Net,通过增加下/上采样次数和减少卷积层通道数量,以及使用暂退法(Dropout)削减神经元连接,在THIMIS火星影像测试集中得到了精确的语义分割结果,证明高度轻量化后的U-Net在陨石坑分割中依然能保持较高的性能。Chen等(2023)通过调整U-Net的下/上采样次数与卷积核通道数,并在跳跃连接中加入通道注意力模块,提高了对THEMIS火星影像中撞击坑的识别精度与效率。Hong等(2022)选择在数据增强阶段提升撞击坑提取效果,该方法对月球DEM数据进行了金字塔裁剪,即在原图中选取随机位置、随机尺寸的多片区域,并将其重采样为 256×256 像素的图像块,扩充了训练集;经过数据增强后,基于“U-Net+模板匹配”的方法识别率提高了约6%。部分学者(Jia等, 2021a, 2022)通过在U-Net框架中引入新的特征提取机制以提高模型精度。例如,Jia等(2021a)将基于嵌套和密集跳跃连接的U-Net++(Zhou等, 2018)应用于月表撞击坑提取,并在U-Net++中融入注意力机制,结合模板匹配在LRO Kuguya月球DEM数据集上实现了撞击坑提取,识别率可达89%,超越了经典U-Net。Jia等(2022)将U-Net作为所设计网络模型HR-GLNet的一个分支来描述局部细节特征,同时使用HRNet(Sun等, 2019)作为全局特征提取分支,可提取行星表面撞击坑、裂缝和峡谷。此外,Wu Y等(2022)使用简化版的UNet3+(Huang等, 2020)实现了撞击坑提取,该模型将下采样阶段中所有尺度的特征图重采样至相同大小,并与上采样阶段的特征图叠加,提高了模型对不同尺寸撞击的特征表征能力。

综上所述,基于深度学习的方法可以自主学习撞击坑特征,克服了传统方法与机器学习方法特征表征的局限性。然而,这类方法更依赖训练数据,面临基准标注数据集缺失、多源数据融合与跨域迁移能力不足等挑战。基于图像分类的方法实现了对原始图像的自动特征提取,是深度学习方法在撞击坑探测领域内的

初步尝试; 基于目标检测模型的方法效率高, 可用于实时导航, 但锚框的尺寸和形状限制了对微小尺寸和不规则形状撞击坑的识别; 基于语义分割的方法则能输出撞击坑的边缘提取结果, 对撞击坑边界的拟合更加精确, 但计算量大, 无法实时预测. 此外, 由于标签是由撞击坑编目数据转换得到的标准圆环, 语义分割模型无法在更细的颗粒度上描述撞击坑轮廓及内部构造.

4.4 撞击坑识别方法的横向对比

本文从撞击坑识别算法、撞击坑对象和基于撞击坑的工程任务三方面对人工专家判读、传统方法、机器学习方法和深度学习方法进行对比分析, 结果见表 3. 在撞击坑识别算法方面, 传统方法属于非监督学习, 其泛化能力较差. 相比之下, 深度学习经过域适应后, 能够从多种复杂场景中精确预测撞击坑, 泛化能力接近专家判读. 在自动化处理方面, 专家判读全程需要依赖专家的干预, 自动化程度低. 机器学习与深度学习较传统方法多出模型训练的步骤, 其自动化程度略低. 在撞击坑识别精度上, 专家判读大场景撞击坑时, 容易遗漏小尺寸撞击坑, 导致漏检率较高. 然而, 专家判读对退化撞击坑和复杂撞击坑的识别效果较好, 因此整体识别率较高. 另外, 机器学习识别效果普遍高于传统方法(Ding等, 2011), 但由于深度学习特征表征能力和预测能力更强大, 致使其与专家判读的精度相当(Lee和Hogan, 2021). 在与工程任务的匹配度方面, 专家判读对地质定年的匹配度最高, 因为主、次撞击坑的区分是影响地质年代非常重要的因素, 而人工判读在这方面具有绝对的优势. 由于传统方法的自动化和轻量化, 其在探测器导航工程中最具优势. 深度学习对小型撞击坑及周围复杂地貌的识别能力较强, 因此最契合着陆区选址.

5 撞击坑下游任务

地外天体撞击坑识别结果主要服务下游的着陆器选址、探测器导航、巡视器路径规划等深空探测工程任务, 以及行星地质构造、形貌特征、水和生命探寻等科学研究.

(1) 着陆器选址. 着陆器选址主要考虑着陆器的安全和着陆区的科研与资源价值. 考虑到着陆器的着陆点最好是平坦、稳定且开阔的表面, 部分大型撞击坑本身就符合这一要求. 例如, “嫦娥四号”月球探测器着陆在“冯·卡门撞击坑”, “勇气号”火星车降落在“古谢夫撞击坑”, “好奇号”火星车降落在“盖尔撞击坑”. 以上被选为着陆区的撞击坑都具有较为平坦开阔的底部. 因此在设计考虑到着陆器选址的撞击坑识别算法时, 需要对着陆候选区内的小型撞击坑、岩石、火山锥等进行精细测绘. 可以选择高于10m/pixel的高精度着陆影像, 并结合DEM数据, 进一步分析预选区内撞击坑的剖面、坑内形态等特征, 从而筛选出适合的着陆位置. 其次, 还需要根据撞击坑密度图, 排除小型撞击坑密集分布的区域. 例如, Wu B等(2022)在“天问一号”着陆器的选址中考虑了撞击坑坡度、密度和岩石丰度三个指标, 最终选择乌托邦平原为着陆区, 该地区地势平坦, 阳光充足. 另外, 乌托邦平原极有可能为古海洋与陆地的交接面, 具有较高的科学探测价值.

(2) 探测器导航. 为解决着陆任务中地面控制中心对远距离探测器通讯延迟较大的问题, 基于撞击坑地标的自主视觉导航方法被用于估计探测器的实时位置和姿态. 该方法首先定位识别天体表面的撞击坑, 并与已知撞击坑数据库进行匹配, 进而实时估计探测器的位姿信息. 整个探测器着陆任务可分为环绕阶段与着陆阶段. 在环绕阶段, 环绕器沿固定轨道运行, 因此撞击坑的物距变化与投影变形较小, 识别难度相对较低.

表 3 不同撞击坑识别方法的横向比较

判别方法	撞击坑识别算法			撞击坑对象			基于撞击坑的工程任务		
	泛化能力	监督学习	自动化程度	撞击坑总体识别率	小目标撞击坑识别率	退化/复杂撞击坑识别率	地质定年	着陆区选址	探测器导航
专家判读	高	×	低	高	低	高	高	中	低
传统方法	低	×	高	低	低	低	低	低	高
机器学习	中	√	中	中	中	中	中	中	低
深度学习	高	√	中	高	高	高	中	高	低

由于导航任务无需识别出全部的撞击坑, 低于100m/pixel的低分辨率影像即可在环绕阶段实现地标撞击坑的识别与匹配。而在着陆阶段, 着陆器需要在短时间内完成序列影像采集、图像处理、匹配和定位, 对算法的实时性要求较高。因此, 可选用与着陆器分辨率相当的影像来预训练模型。

(3) 巡视器路径规划。巡视器对周围场景感知、避障和导航等任务目前主要采用数据下传地面控制中心, 然后由控制中心处理数据, 继而再上传指令的方式控制巡视器的每一步前进。但由于深空探测受到传输距离和通信带宽的限制, 数据下派和指令上传往往存在较大的延迟, 阻碍了巡视器大范围、长距离的定位和导航。为此需要开展巡视器在线场景的实时感知, 这就需要设计高精度且轻量化的感知算法, 以适应巡视器有限的数据处理能力, 用于识别巡视器周围的撞击坑等显著地貌, 以生成坡度图和避障图, 满足高效实时导航的需求。

(4) 精确定年。行星地质年代的测定有助于推演影响行星历史的重要地质过程。当前, 主要从微观和宏观两个角度测定行星的地质年代。微观层面, 通过检查撞击事件暴露的岩石和沉积物层, 利用放射性元素测算行星表面不同地质区域的绝对年龄。宏观层面, 基于撞击坑尺寸-频率关系的行星地表年代测定方法较为成熟。Neukum和Ivanov(1994)认为陨石撞击的区域事件是随机的, 因此地质年代越久远的地区受到撞击的概率越高, 其表面的撞击坑累计数量也就越多。基于该理论, 可利用撞击坑的空间密度来推断不同地质区域的相对年龄。例如, 对火星表面撞击坑密度的研究(Tanaka, 1986)勾勒出了火星地质史上的四个地质时期: 前诺亚纪(45~41亿年前)、诺亚纪(41~37亿年前)、西方纪(37~30亿年前)和亚马逊纪(30亿年前至今)。

(5) 多地貌一体化制图。在地外天体表面高精度测图任务中, 除了撞击坑, 还需要根据具体天体的特点探测其他具有研究价值的地貌, 譬如石块、火山锥、山脊、沟槽、凹锥、横向风成脊等。譬如, 对月球的研究主要集中在环形和线性构造的识别上; 对火星的构造地貌、风成地貌、水成地貌和岩石地貌, 目前都有相应的识别算法(邱凯昌等, 2021); 对小行星巨型石块的识别目前也有相关研究(Zhu等, 2021)。然而, 由于数据集和网络模型的精度和效率限制, 目前缺乏一种能

够一次性识别多类地貌的方法。近期, 深度学习AI大模型的出现为实现这一目标带来了希望。AI大模型经过海量数据的预训练, 在一定程度上缓解了训练数据不足的问题, 并能够以极高的精度实现地外天体多类地貌的一体化语义分割。此外, 当今深空探测的载荷多样, 包括激光、微波和物质探测载荷等。将这些不同数据源融合起来可以取长补短, 充分发挥各自的优势, 从而更精确地获取撞击坑的形貌特征和生化组分信息。这有助于我们更深入地理解行星地貌的形成和演化过程, 同时为任务规划和资源探测提供更可靠的数据支持。

(6) 追踪水和生命。在太阳系中, 火星被认为是与地球最相似的行星之一, 其表面形成了大量河道, 并保留了流水冲刷的痕迹。研究表明, 在火星的Hellas撞击盆地边缘的沉积序列中, 河流的沉积可以追溯到约37亿年前(Salese等, 2020)。而根据撞击坑密度年表, 大量陨石撞击火星的时间大约在41亿至37亿年前的诺亚纪。因此, 火星的水体与撞击坑地貌和撞击事件之间可能存在密切的联系。精确测绘火星的河床、撞击坑以及坑内各类沉积地貌对于推断火星在液态水大量存在时期的流向、径流量、水储量等特征以及水体活动的演变过程具有重要意义。这进一步有助于推测火星液态水消失的原因, 并寻找保存在火星岩石中古代微生物生命的迹象。此外, 针对月球, 印度的“月船一号”探测器在月球北极的40多个撞击坑内发现了“水冰”的迹象。另外, 相关研究(Feldman等, 2001; Li等, 2018)也已经发现在月球两极存在“水冰”资源的直接证据。而中国嫦娥探月工程中规划的“嫦娥七号”, 其关键目标就是对月球南极“水冰”资源进行详细勘测, 为人类登月提供饮用水、制造燃料及支持人类在月球上建立月面移动实验室。

6 问题与应对策略

6.1 撞击坑对象层面

特殊形态撞击坑提取不精确。特殊形态撞击坑包含重叠、退化与具有中央峰或中央环的各类复杂撞击坑。针对半重叠撞击坑, 可通过淹没算法(O'Callaghan和Mark, 1984)或“线性抗差估计理论”对其进行提取。针对退化撞击坑和复杂撞击坑, 前者在图像上具有模糊的边缘特征, 可使用局部直方图分析来增强信噪比;

后者坑底常有中央峰隆起, 可基于“地形分析方法”确定中央峰与复杂撞击坑的位置, 例如, Xie等(2013)通过计算中央峰周围的环状平坦区域质心来推算复杂撞击坑中心. 另外, 基于深度学习的识别方法则缺少相应的训练样本, 致使对该类撞击坑的识别效果差、识别难度大; 通过对特殊形态撞击坑样本进行数据增强, 可进一步改善深度学习网络对该类撞击坑的特征编码和表征.

撞击坑尺寸分布不均衡. 由于撞击坑的尺寸与数量遵循幂律分布, 导致撞击坑的“尺频”分布严重不均, 中大型撞击坑较为零星, 而绝大多数撞击坑直径小于 3km. 在监督学习中, “尺频”分布的不均匀性会导致训练样本类别不平衡, 即中大型撞击坑的训练样本数量远小于小型撞击坑, 使得分类器对中大型撞击坑的识别效果较差. 另外, 由于撞击坑的尺寸差异极大, 大中型撞击坑无法与小型撞击坑维持在同样大小的感受野. 为此, 在数据层面, 可使用金字塔裁剪方法来增强训练数据集(Hong等, 2022), 以调整部分过大或过小的撞击坑至相同大小的感受野, 或者在网络模型中设置多个并行子网络, 通过设置不同的锚框大小, 分别预测不同尺寸的撞击坑(Wang等, 2018). 在网络模型层面, 可利用跳跃连接、密集连接、多尺度融合、Transformer框架等技术来增强撞击坑的上下文语义信息, 例如, Yang和Cai(2021)将HRNet融入目标检测网络的特征提取模块, 提高了小型撞击坑的探测精度. 一般而言, 基于DEM数据且充分利用内部构造特征的传统方法在小目标提取上效果较好, 如使用淹没算法(Buc和Stepinski, 2007)或用剖面分析(骆磊等, 2014), 能够识别直径最小为6个像素的撞击坑. 在基于光学影像的撞击坑识别方法中, 机器学习比传统方法能够识别出更多的小型撞击坑, 例如, Martins等(2009)提出的利用“类哈尔”特征与Boosting集成学习模型能识别最小直径为7个像素的撞击坑, 优于模板匹配所识别的最小直径为10个像素的撞击坑(Bandeira等, 2007). 在深度学习中, 目标检测模型在小目标撞击坑的识别方面表现最出色, 且优于机器学习. 例如, 基于相同影像数据集, 目标检测模型(Wang等, 2018)对小撞击坑的识别精度远远优于机器学习方法(Urbach和Stepinski, 2009). 同样, 使用相同数据集进行的研究也表明, 目标检测模型(Yang和Cai, 2021)在最小撞击坑的识别方面也明显优于语义分割网络(DeLatte等, 2019).

6.2 撞击坑数据层面

缺乏撞击坑影像基准标注数据集. 尽管DeLatte等(2019)开源了基于Robbins火星撞击坑编目数据(Robbins和Hynek, 2012)制作的语义分割标签数据, 但撞击坑图像标签数据集仍然较为稀缺, 导致不同方法使用的训练集与测试集不一致, 不同撞击坑识别方法之间往往难以横向比较. 为实现对比, 往往需要重新训练模型, 时间成本较高. 建立统一的行星撞击坑影像标注数据库或统一的判别标准有助于改善此类问题, 但面临下述两方面的挑战: (1) 专家对撞击坑的判别标准不统一, 特别是在“次生撞击坑”和“退化撞击坑”的判定上, 很容易将其判别为非撞击坑, 导致不同专家在对相同撞击坑的判读上存在较大差异. (2) 虽然当前大量的撞击坑编目数据库有力地支撑了基于机器学习和深度学习的撞击坑识别方法, 但撞击坑编目数据需要经过转换处理后才能作为有效的撞击坑影像标签. 譬如, 在训练语义分割模型时, 需要先将撞击坑按照编目数据库中的坐标和直径在影像中展成圆或特定厚度的圆环; 在训练目标检测模型时, 则需将编目数据转换成撞击坑目标的最小包围框; 不同的转化方法导致生成的撞击坑影像标签差异较大.

多模态撞击坑数据的融合力度不够. 当前基于深度学习检测撞击坑方法往往不能充分融合多模态数据, 未能充分挖掘多模态数据之间的互补性. 这一方面需要考虑多模态数据的配准和尺度问题, 另一方面需要考虑融合策略和融合力度, 以便充分发挥多模态数据的互补优势. 譬如, 传统撞击坑提取方法(罗中飞等, 2014; Kang等, 2015)在耦合多模态数据时, 一般通过光学影像初步识别撞击坑, 再利用DEM数据进一步核验, 这种两步策略未能在特征图层面实现高层次的数据融合. 在深度学习领域, 多模态数据融合一般分为通道维融合和特征维融合两类(Wang和Li, 2021), 前者在输入网络模型前将多模态数据在通道维叠加, 后者则将多模态数据分别输入不同网络层, 单独提取特征后再合并结果并输入后续网络层.

6.3 撞击坑识别模型层面

撞击坑识别算法往往无法自适应识别尺寸差异较大的撞击坑、无法准确分割撞击坑边缘、缺乏对于不同天体陨石坑探测的迁移能力. 基于无锚框(Anchor-

free)的目标检测、AI大模型、迁移学习等新技术有助于解决上述问题,提升撞击坑探测精度。

无法适应撞击坑的尺寸和几何形状变化。目前大多数目标检测算法(Ren等, 2015; Liu等, 2016; Lin等, 2017)受限于预定义锚框的尺寸和矩形形状,无法解决由于撞击坑尺寸差异大以及投影产生的严重几何畸变所造成的问题。而无锚框目标检测模型是一种不依赖预先定义的锚框或候选区域的目标检测模型,例如FCOS(Tian等, 2019)。相比基于锚框的目标检测模型,无锚框模型能更好地适应不同尺度和形状的目标,且无需设计纵横比等超参数,减少了计算复杂度。例如,C-Moon-Net(庞程程等, 2022)和CAMDA-Net(Cao等, 2023)基于无锚框检测网络CenterNet(Duan等, 2019)实现了月球DEM撞击坑的快速和精确检测。

无法准确分割撞击坑边缘与细粒度分割撞击坑内部区域。在着陆区选择与地形地貌绘制任务中,需要对撞击坑的具体边缘轮廓与坑内中央峰等构造进行精细的语义分割。受到训练集质量与算力限制,目前常用的语义分割模型无法满足上述任务需要,而应用AI大模型有望解决该问题。自2017年基于自注意力机制与全连接神经网络的Transformer(Vaswani等, 2017)被提出后,一类基于Transformer的改进模型,譬如ViT(Vision Transformer)(Dosovitskiy等, 2020)、Swin Transformer(Liu等, 2021)、SAM(Segment Anything Model)(Kirillov等, 2023)等开始展现出替代CNN和RNN模型的趋势,这些模型通常需要大量的计算资源和数据来训练,称为AI大模型。AI大模型经预训练后的模型只需要微调参数即可实现特定的视觉任务,极大地提高了模型的准确率和泛化能力。AI大模型满足了对复杂撞击坑细粒度识别的需求,例如, Giannakis等(2023)基于SAM模型实现了撞击坑实例分割。该方法首先使用SAM对整幅图像进行实例分割,生成每个对象的掩膜,随后分析每个分割掩膜并保留形状为圆或椭圆的掩膜,最后提取掩膜边界并利用椭圆拟合边缘。但考虑到模型参数量较大,AI大模型无法做到实时的预测,也较难集成到卫星探测器中。因此,AI大模型适用于对行星地形地貌制图、年代测定、着陆器选址等非实时的任务,能够极大地提高撞击坑的探测精度。

模型对数据的迁移能力不强。由于地外天体撞击坑训练数据不足且不同天体间的撞击坑存在一定的差异性,限制了深度模型的有效训练和天体间的跨域预

测。因此,只有部分标签的半监督、含有部分正确标签的“不精确弱监督”和只有粗粒度标签的“不准确弱监督”对撞击坑探测研究将具有较高的价值。因此,可以通过目视解译,精细标注小部分训练集,并利用目前较为先进的半监督目标检测模型(Mi等, 2022; Yang Q等, 2021)实现撞击坑识别。另外,以SAM为首的“交互式分割”使得粗粒度的标注可以作为深度学习网络的输入,提高了撞击坑的实例分割的灵活性和泛化能力。在跨域预测方面,基于预训练的迁移学习将会成为缺乏标签数据的新天体撞击坑研究的有效方法。例如,Yang等(2020)将基于“嫦娥一号”训练模型的权重迁移到“嫦娥二号”数据训练模型中,并结合半监督学习,实现了撞击坑识别。另外,一些相关工作(Yang H等, 2021; Latorre等, 2022; Yang和Cai, 2022; Zhang等, 2023; Cao等, 2023)使用基于域适应方法来训练撞击坑目标检测网络,提升了模型的泛化能力。

6.4 撞击坑下游任务驱动层面

当前大多数撞击坑探测方法为非任务驱动,未考虑相关的下游任务,信息挖掘不全面,实用性不强。陨石坑地质单元定年、着陆器选址、巡视器导航、地质地貌研究等任务对撞击坑相关信息的需求各有侧重,譬如,地质单元的定年需要统计撞击坑的密度和分布;着陆器选址应该考虑陨石坑的位置、尺寸、深度、坑底几何形态、撞击坑抛射物堆积层等;在选址的基础上,巡视器导航任务还需要进一步考虑坑壁崩塌和岩层露头、地质结构和岩性、光照等各类环境因素;开展撞击坑构造和微观地貌研究则需要提供撞击坑大小直径等基本特征、坑壁形态、坑底地貌、撞击坑周围抛射物堆积层等信息。因此将特定下游任务的需求融入到算法模型的设计中,能够更好地指导撞击坑相关信息的综合提取,从而实现与下游应用的无缝衔接。

7 结论和展望

随着遥感技术、通讯技术、人工智能技术和超级计算集群技术的发展,人类在深空固态天体撞击坑探测方面取得了重要的研究进展,为人类探索系内行星起源和演化历史打开了一扇窗户,并推动了行星科学的发展。未来,随着人类对星际旅行、火星移民等宇宙探索的渴望,撞击坑识别相关的研究将朝着更遥远

的系内行星甚至系外行星, 以及面向更加具体的深空探测工程任务和更精细的行星科学研究方向发展。

具体而言, 在数据层面, 撞击坑的研究将涵盖越来越丰富的多光谱影像、激光雷达数据、多视角影像、热红外影像、合成孔径雷达影像等泛在多模态遥感数据源。此外, 撞击坑的矢量编目数据也将从仅有坐标和半径的简单表格过渡到包含多种属性的撞击坑标签数据, 这些数据能够直接用于训练语义分割、目标检测等计算机视觉模型。在算法设计层面, 现有的撞击坑自动识别技术将根据具体任务进一步优化模型结构。例如, 小目标识别、弱监督学习、迁移学习、主动学习、强化学习、多任务互增强分支网络等深度学习技术将进一步与撞击坑目标识别进行无缝融合, 以提高撞击坑探测的精度和泛化能力。在任务层面, 借助更高分辨率的数据和更智能的探测算法, 行星表面各类撞击坑形态结构和地貌特征将会被描述得更加全面和精细。在此基础上将实现撞击坑研究从“形态几何建模”向“成因物理建模”方向的发展, 以解释撞击坑的地质成因和演化过程。行星科学将与天体物理学、地质学、天体化学、矿物学等多学科进行交叉融合, 共同揭示行星内部结构和成分、生命起源和生命宜居性等重要科学问题。

参考文献

邸凯昌, 刘斌, 刘召芹. 2018. 火星遥感制图技术回顾与展望. *航天器工程*, 27: 10–24

邸凯昌, 叶乐佳, 王润之, 王晔昕. 2021. 行星遥感影像目标识别与分类进展. *遥感学报*, 25: 365–380

丁萌, 曹云峰, 吴庆宪. 2009. 月面灰度图像中的陨石坑检测. *应用科学学报*, 27: 156–160

冯军华, 崔祜涛, 崔平远, 田阳. 2010. 行星表面陨石坑检测与匹配方法. *航空学报*, 31: 1858–1863

李春来. 2013. 嫦娥一号三线阵CCD数据摄影测量处理及全月球数字地形图. *测绘学报*, 42: 853–860, 868

李春来, 刘建军, 任鑫, 牟伶俐, 邹永廖, 张洪波, 吕昌, 刘建忠, 左维, 苏彦. 2010a. 嫦娥一号图像数据处理与全月球影像制图. *中国科学: 地球科学*, 40: 294–306

李春来, 任鑫, 刘建军, 邹小端, 牟伶俐, 王建宇, 舒嵘, 邹永廖, 张洪波, 吕昌. 2010b. 嫦娥一号激光测距数据及全月球DEM模型. *中国科学: 地球科学*, 40: 281–293

李春来, 刘建军, 任鑫, 严韦, 左维, 牟伶俐, 张洪波, 苏彦, 温卫斌, 谭旭, 张晓霞, 王文睿, 付强, 耿良, 张广良, 赵葆常, 杨建峰, 欧阳自

远. 2018. 基于嫦娥二号立体影像的全月高精度地形重建. *武汉大学学报-信息科学版*, 43: 485–495

刘建军, 任鑫, 谭旭, 李春来. 2013. 嫦娥二号CCD立体相机数据预处理与数据质量评价. *武汉大学学报-信息科学版*, 38: 186–190

刘宇轩, 李春来, 刘建军. 2018. 一种基于等高线的小型撞击坑识别方法. *天文研究与技术*, 15: 479–486

罗中飞, 康志忠, 刘心怡. 2014. 融合嫦娥一号CCD影像与DEM数据的月球撞击坑自动提取和识别. *测绘学报*, 43: 924–930

骆磊, 王心源, 郭华东, 李超, 吉玮. 2014. 嫦娥一号DEM数据月表撞击坑自动检测. *遥感学报*, 18: 105–116

庞程程, 张华春, 张岩岩. 2022. 基于端到端的多尺度月球陨石坑检测方法. *雷达科学与技术*, 20: 65–73

王丹, 丁孝忠, 韩同林, 韩坤英, 庞健峰, 许可娟, 王梁. 2017. 月球第谷区域内“冻融地貌”的发现. *地球学报*, 38: 971–980

岳宗玉, 史珂, 邸凯昌, 林杨挺, 苟盛. 2023. 撞击坑研究进展与展望. *中国科学: 地球科学*, 53: 2482–2493

张荣桥, 黄江川, 赫荣伟, 耿言, 孟林智. 2019. 小行星探测发展综述. *深空探测学报*, 6: 417–423

张吴明, 张孝斌, 李巧枝, 阎广建, 周国清. 2013. 低太阳高度角月球影像的陨石坑自动提取方法. *宇航学报*, 34: 1246–1252

Bandeira L Ç, Saraiva J É, Pina P. 2007. Impact crater recognition on Mars based on a probability volume created by template matching. *IEEE Trans Geosci Remote Sens*, 45: 4008–4015

Barata T, Alves E I, Saraiva J, Pina P. 2004. Automatic recognition of impact craters on the surface of Mars. Porto: Image Analysis and Recognition: International Conference, ICIAR. 489–496

Barker M K, Mazarico E, Neumann G A, Zuber M T, Haruyama J, Smith D E. 2016. A new Lunar digital elevation model from the Lunar orbiter laser altimeter and SELENE terrain camera. *Icarus*, 273: 346–355

Barlow N G, Mest S C, Gibbs V B, Kinser R M. 2012. Compilation of a global GIS crater database for the Moon. In: Proceedings of AAS/Division for Planetary Sciences Meeting Abstracts. 44: 311.05

Becker K, Weller L, Edmundson K, Becker T, Robinson M, Enns A, Solomon S. 2012. Global controlled mosaic of Mercury from Messenger orbital images. The Woodlands: 43rd Annual Lunar and Planetary Science Conference. (1659): 2654

Besse S, Lamy P, Jorda L, Marchi S, Barbieri C. 2012. Identification and physical properties of craters on Asteroid (2867) Steins. *Icarus*, 221: 1119–1129

Bue B D, Stepinski T F. 2007. Machine detection of Martian impact craters from digital topography data. *IEEE Trans Geosci Remote Sens*, 45: 265–274

Canny J. 1986. A computational approach to edge detection. *IEEE Trans Pattern Anal Mach Intell*, PAMI-8: 679–698

Cao Z, Kang Z, Hu T, Yang Z, Zhu L, Ye C. 2023. Cross-attention

- induced multilayer domain adaptation network for extraction of sub-kilometer craters from HiRIC images. *Icarus*, 407: 115776
- Caplinger M A, Malin M C. 2001. Mars orbiter camera geodesy campaign. *J Geophys Res*, 106: 23595–23606
- Chan J C W, Paelinckx D. 2008. Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sens Environ*, 112: 2999–3011
- Chatterjee S, Chakraborty S, Nath A, Chowdhury P R, Deshmukh B. 2023. Near-real-time detection of craters: A YOLO v5 based approach. Hyderabad: 2023 International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS). 1: 1–4
- Chen D, Hu F, Mathiopoulos P T, Zhang Z, Peethambaran J. 2023. MC-UNet: Martian crater segmentation at semantic and instance levels using U-Net-Based convolutional neural network. *Remote Sens*, 15: 266
- Cheng Y, Johnson A E, Matthies L H, Olson C F. 2003. Optical landmark detection for spacecraft navigation. In: 13th AAS/AIAA Space Flight Mechanics Meeting. 1–19
- Christensen P R, Bandfield J L, Bell III J F, Gorelick N, Hamilton V E, Ivanov A, Jakosky B M, Kieffer H H, Lane M D, Malin M C, McConnochie T, McEwen A S, McSween Jr. H Y, Mehall G L, Moersch J E, Nealon K H, Rice Jr. J W, Richardson M I, Ruff S W, Smith M D, Titus T N, Wyatt M B. 2003. Morphology and composition of the surface of Mars: Mars odyssey themis results. *Science*, 300: 2056–2061
- Cohen J P, Lo H Z, Lu T, Ding W. 2016. Crater detection via convolutional neural networks. arXiv preprint, arXiv: 1601.00978
- Dalal N, Triggs B. 2005. Histograms of oriented gradients for human detection. San Diego: 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05). 1: 886–893
- DeLatte D M, Crites S T, Guttenberg N, Tasker E J, Yairi T. 2019. Segmentation convolutional neural networks for automatic crater detection on Mars. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 12: 2944–2957
- Ding M, Cao Y F, Wu Q X. 2008. Autonomous craters detection from planetary image. Dalian: 2008 3rd International Conference on Innovative Computing Information and Control. 443–443
- Ding W, Stepinski T F, Mu Y, Bandeira L, Ricardo R, Wu Y, Lu Z, Cao T, Wu X. 2011. Subkilometer crater discovery with boosting and transfer learning. *ACM Trans Intell Syst Technol*, 2: 1–22
- Dong W, Roy P, Peng C, Isler V. 2021. Ellipse R-CNN: Learning to infer elliptical object from clustering and occlusion. *IEEE Trans Image Process*, 30: 2193–2206
- Doppenberg W. 2021. Autonomous Lunar orbit navigation with Ellipse R-CNN. Dissertation for Master's Degree. Delft: Delft University of Technology
- Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, Dehghani M, Minderer M, Heigold G, Gelly S, Uszkoreit J, Houlsby N. 2020. An image is worth 16×16 words: Transformers for image recognition at scale. arXiv preprint, arXiv:2010.11929
- Duan K, Bai S, Xie L, Qi H, Huang Q, Tian Q. 2019. Centernet: Keypoint triplets for object detection. Seoul: IEEE/CVF International Conference on Computer Vision. 6569–6578
- Eliason E, Lee E, Becker T, Weller L, Isbell C, Staid M, Gaddis L, McEwen A, Robinson M, Duxbury T, Steutel D, Blewett D T, Lucey P G. 2003. A Near-Infrared (NIR) global multispectral map of the Moon from Clementine. *Lunar and Planetary Science*, XXXIV
- Emami E, Bebis G, Nefian A, Fong T. 2015. Automatic crater detection using convex grouping and convolutional neural networks. Las Vegas: Advances in Visual Computing: 11th International Symposium. 213–224
- Emami E, Bebis G, Nefian A, Fong T. 2017. On crater verification using mislocalized crater regions. Santa Rosa: Proceedings of 2017 IEEE Winter Conference on Applications of Computer Vision (WACV). 1098–1104
- Emami E, Ahmad T, Bebis G, Nefian A, Fong T. 2018a. On crater classification using deep convolutional neural networks. In: Proceedings of 49th Annual Lunar and Planetary Science Conference. 1–2
- Emami E, Ahmad T, Bebis G, Nefian A, Fong T. 2018b. Lunar crater detection via region-based convolutional neural networks. In: Proceedings of 49th Annual Lunar and Planetary Science Conference. (2083): 2381
- Emami E, Ahmad T, Bebis G, Nefian A, Fong T. 2019. Crater detection using unsupervised algorithms and convolutional neural networks. *IEEE Trans Geosci Remote Sens*, 57: 5373–5383
- Feldman W C, Maurice S, Lawrence D J, Little R C, Lawson S L, Gasnault O, Wiens R C, Barraclough B L, Elphic R C, Prettyman T H, Steinberg J T, Binder A B. 2001. Evidence for water ice near the Lunar poles. *J Geophys Res*, 106: 23231–23251
- Ferguson R, Hare T, Laura J. 2018. HRSC and MOLA blended digital elevation model at 200m v2. Astrogeology PDS Annex, US Geological Survey. 400
- Ford J P. 1993. Guide to Magellan image interpretation. National Aeronautics and Space Administration, Jet Propulsion Laboratory, California Institute of Technology
- Ford P G. 1992. Magellan global topography, emissivity, reflectivity, and slope data. Technical report, MGN-V-RDRS-5-GDR-TOPOGRAPHIC-V1. 0, MGN-V-RDRS-5-GDR-EMISSION-V1. 0,

- MGN-V-RDRS-5-GDR-REFLECTIVITY-V1. 0, and MGN-V-RDRS-5-GDR-SLOPE-V1. 0, NASA planetary data system, <http://pds-geosciences.wustl.edu/missions/magellan/gxdr/index.htm>
- Gaddis L, Isbell C, Staid M, Eliason E, Lee E M, Weller L, Sucharski T, Lucey P, Blewett D, Hinrichs J, Steutel D. 2007. The Clementine NIR Global Lunar Mosaic. PDS Volumes USA_NA-SA_PDS_CL_5001 through, 5078
- Galilei G. 1610. Sidereus Nuncius, Venetiis. Venice: Apud Thomam BaglionumItaly
- Giannakis I, Bhardwaj A, Sam L, Leontidis G. 2023. Deep learning universal crater detection using Segment Anything Model (SAM). arXiv preprint, arXiv:2304.07764
- Gou S, Yue Z, Di K, Liu Z. 2018. A global catalogue of Ceres impact craters ≥ 1 km and preliminary analysis. *Icarus*, 302: 296–307
- Gwinner K, Scholten F, Preusker F, Elgner S, Roatsch T, Spiegel M, Schmidt R, Oberst J, Jaumann R, Heipke C. 2010. Topography of Mars from global mapping by HRSC high-resolution digital terrain models and orthoimages: Characteristics and performance. *Earth Planet Sci Lett*, 294: 506–519
- Haralick R M, Shanmugam K, Dinstein I H. 1973. Textural features for image classification. *IEEE Trans Syst Man Cybern*, SMC-3: 610–621
- Haruyama J, Ohtake M, Matsunaga T, Morota T, Honda C, Yokota Y, Ogawa Y, LISM working group. 2009. SELENE (Kaguya) terrain camera observation results of nominal mission period. In: Proceedings of 40th Annual Lunar and Planetary Science Conference. 1553
- Head III J W, Fassett C I, Kadish S J, Smith D E, Zuber M T, Neumann G A, Mazarico E. 2010. Global distribution of large Lunar craters: Implications for resurfacing and impactor populations. *Science*, 329: 1504–1507
- Heiken G, Vaniman D, French B M. 1991. Lunar sourcebook: A user's guide to the Moon. Number 1259. CUP Archive
- Henriksen M R, Manheim M R, Burns K N, Seymour P, Speyerer E J, Deran A, Boyd A K, Howington-Kraus E, Rosiek M R, Archinal B A, Robinson M S. 2017. Extracting accurate and precise topography from LROC narrow angle camera stereo observations. *Icarus*, 283: 122–137
- Herrick R R, Phillips R J. 1994. Implications of a global survey of Venusian impact craters. *Icarus*, 111: 387–416
- Hong Z, Fan Z, Zhou R, Pan H, Zhang Y, Han Y, Wang J, Yang S, Jin Y. 2022. Pyramidal image segmentation based on U-Net for automatic multiscale crater extraction. *Sens Mater*, 34: 237–250
- Hsu C Y, Li W, Wang S. 2021. Knowledge-driven GeoAI: Integrating spatial knowledge into multi-scale deep learning for Mars crater detection. *Remote Sens*, 13: 2116
- Hu M K. 1962. Visual pattern recognition by moment invariants. *IEEE Trans Inform Theor*, 8: 179–187
- Huang H M, Lin L F, Tong R F, Hu H J, Zhang Q W, Iwamoto Y, Han X H, Chen Y W, Wu J. 2020. UNet 3+: A full-scale connected UNet for medical image segmentation. In: Proceedings of ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP). 1055–1059
- Isbell C E, Eliason E M, Adams K C, Becker T L, Bennett A L, Lee E M, McEwen A, Robinson M, Shinaman J, Weller L A. 1999. Clementine: A multi-spectral digital image model archive of the Moon. In: Proceedings of Lunar and Planetary Science Conference. 1812
- Janiesch C, Zschech P, Heinrich K. 2021. Machine learning and deep learning. *Electron Markets*, 31: 685–695
- Jia Y, Liu L, Zhang C. 2021a. Moon impact crater detection using nested attention mechanism based UNet++. *IEEE Access*, 9: 44107–44116
- Jia Y, Wan G, Liu L, Wang J, Wu Y, Xue N, Wang Y, Yang R. 2021b. Split-attention networks with self-calibrated convolution for Moon impact crater detection from multi-source data. *Remote Sens*, 13: 3193
- Jia Y, Liu L, Peng S, Feng M, Wan G. 2022. An efficient high-resolution global-local network to detect Lunar features for space energy discovery. *Remote Sens*, 14: 1391
- Kang Z, Luo Z, Hu T, Gamba P. 2015. Automatic extraction and identification of Lunar impact craters based on optical data and DEMs acquired by the Chang'E satellites. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 8: 4751–4761
- Kim J R, Muller J P, van Gasselt S, Morley J G, Neukum G. 2005. Automated crater detection, a new tool for Mars cartography and chronology. *Photogramm Eng Remote Sens*, 71: 1205–1217
- Kirillov A, Mintun E, Ravi N, Mao H, Rolland C, Gustafson L, Xiao T, Whitehead S, Berg A C, Lo W Y, Dollár P, Girshick R. 2023. Segment anything. arXiv preprint, arXiv:2304.02643
- Kirk R L, Howington-Kraus E, Rosiek M R, Anderson J A, Archinal B A, Becker K J, Cook D A, Galuszka D M, Geissler P E, Hare T M, Holmberg I M, Keszthelyi L P, Redding B L, Delamere W A, Gallagher D, Chapel J D, Eliason E M, King R, McEwen A S. 2008. Ultrahigh resolution topographic mapping of Mars with MRO HiRISE stereo images: Meter-scale slopes of candidate Phoenix landing sites. *J Geophys Res*, 113: 2007JE003000
- Koutchmy O, Koutchmy S, Nitschelm C, Sykora J, Smartt R N. 1988. Image processing of coronal pictures. In: Proceedings of Solar and Stellar Coronal Structure and Dynamics. 256–266
- Krüger T, Hergarten S, Kenkmann T. 2018. Deriving morphometric parameters and the simple-to-complex transition diameter from a high-resolution, global database of fresh Lunar impact craters

- ($D \geq 3$ km). *J Geophys Res-Planets*, 123: 2667–2690
- Kurita T, Otsu N, Abdelmalek N. 1992. Maximum likelihood thresholding based on population mixture models. *Pattern Recognition*, 25: 1231–1240
- La Grassa R, Gallo I, Re C, Cremonese G, Landro N, Pernechele C, Simioni E, Gatti M. 2022. An adversarial generative network designed for high-resolution monocular depth estimation from 2D HiRISE images of Mars. *Remote Sens*, 14: 4619
- La Grassa R, Cremonese G, Gallo I, Re C, Martellato E. 2023. YOLOLens: A deep learning model based on super-resolution to enhance the crater detection of the planetary surfaces. *Remote Sens*, 15: 1171
- Latorre F, Spiller D, Curti F. 2022. Autonomous crater detection on asteroids using a fully-convolutional neural network. arXiv preprint, 2022.08.01
- Lee C. 2019. Automated crater detection on Mars using deep learning. *Planet Space Sci*, 170: 16–28
- Lee C, Hogan J. 2021. Automated crater detection with human level performance. *Comput Geosci*, 147: 104645
- Lee H, Choi H L, Jung D, Choi S. 2020. Deep neural network-based landmark selection method for optical navigation on Lunar highlands. *IEEE Access*, 8: 99010–99023
- Leroy B, Medioni G, Johnson E, Matthies L. 2001. Crater detection for autonomous landing on asteroids. *Image Vision Computing*, 19: 787–792
- Li M, Liang J, Yan P, Tian X. 2022. Mars crater detection based on YOLO structure using TIR data. In: Proceedings of 2022 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA). 530–533
- Li S, Lucey P G, Milliken R E, Hayne P O, Fisher E, Williams J P, Hurley D M, Elphic R C. 2018. Direct evidence of surface exposed water ice in the Lunar polar regions. *Proc Natl Acad Sci USA*, 115: 8907–8912
- Li W, Zhou B, Hsu C Y, Li Y, Ren F. 2017. Recognizing terrain features on terrestrial surface using a deep learning model: An example with crater detection. In: Proceedings of the 1st Workshop on Artificial Intelligence and Deep Learning for Geographic Knowledge Discovery. 33–36
- Lin T Y, Goyal P, Girshick R, He K, Dollár P. 2017. Focal loss for dense object detection. In: Proceedings of the IEEE International Conference on Computer Vision. 2980–2988
- Liu D, Chen M, Qian K, Lei M, Zhou Y. 2017. Boundary detection of dispersal impact craters based on morphological characteristics using Lunar digital elevation model. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 10: 5632–5646
- Liu J J, Ren X, Yan W, Li C L, Zhang H, Jia Y, Zeng X G, Chen W L, Gao X Y, Liu D W, Tan X, Zhang X X, Ni T, Zhang H B, Zuo W, Su Y, Wen W B. 2019. Descent trajectory reconstruction and landing site positioning of Chang'E-4 on the Lunar farside. *Nat Commun*, 10: 4229
- Liu Q, Cheng W, Yan G, Zhao Y, Liu J. 2019. A machine learning approach to crater classification from topographic data. *Remote Sens*, 11: 2594
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y, Berg A C. 2016. SSD: Single Shot Multibox Detector. Amsterdam: 14th European Conference Computer Vision-ECCV 2016. 21–37
- Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S, Guo B. 2021. Swin transformer: Hierarchical vision transformer using shifted windows. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 10012–10022
- Maass B, Woicke S, Oliveira W M, Razgus B, Krüger H. 2020. Crater navigation system for autonomous precision landing on the Moon. *J Guidance Control Dyn*, 43: 1414–1431
- Malin M C, Bell Iii J F, Cantor B A, Caplinger M A, Calvin W M, Clancy R T, Edgett K S, Edwards L, Haberle R M, James P B, Lee S W, Ravine M A, Thomas P C, Wolff M J. 2007. Context camera investigation on board the Mars Reconnaissance Orbiter. *J Geophys Res*, 112: 2006JE002808
- Malin M, Revine M. 1998. Clementine high resolution camera mosaicking project. NASA STI/Recon Technical Report N, 1:00259
- Martins R, Pina P, Marques J S, Silveira M. 2009. Crater detection by a boosting approach. *IEEE Geosci Remote Sens Lett*, 6: 127–131
- McEwen A S, Eliason E M, Bergstrom J W, Bridges N T, Hansen C J, Delamere W A, Grant J A, Gulick V C, Herkenhoff K E, Keszthelyi L, Kirk R L, Mellon M T, Squyres S W, Thomas N, Weitz C M. 2007. Mars reconnaissance orbiter's high resolution imaging science experiment (HiRISE). *J Geophys Res*, 112: 2005JE002605
- Mi P, Lin J, Zhou Y, Shen Y, Luo G, Sun X, Cao L, Fu R, Xu Q, Ji R. 2022. Active teacher for semi-supervised object detection. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 14482–14491
- Neukum G, Ivanov B A. 1994. Crater size distributions and impact probabilities on Earth from Lunar, terrestrial-planet, and asteroid cratering data. *Hazards due to Comets and Asteroids*, 359: 359–416
- O'Callaghan J F, Mark D M. 1984. The extraction of drainage networks from digital elevation data. *Comput Vision Graphics Image Processing*, 28: 323–344
- Ody A, Poulet F, Langevin Y, Bibring J P, Bellucci G, Altieri F, Gondet B, Vincendon M, Carter J, Manaud N. 2012. Global maps of anhydrous minerals at the surface of Mars from OMEGA/MEx. *J Geophys Res*, 117: 2012JE004117
- Pan L, Quantin-Nataf C, Breton S, Michaut C. 2019. The impact origin and evolution of Chryse Planitia on Mars revealed by buried craters.

- Nat Commun, 10: 4257
- Pedrosa M M, de Azevedo S C, da Silva E A, Dias M A. 2017. Improved automatic impact crater detection on mars based on morphological image processing and template matching. *Geomatics Nat Hazards Risk*, 8: 1306–1319
- Povilaitis R Z, Robinson M S, van der Bogert C H, Hiesinger H, Meyer H M, Ostrach L R. 2018. Crater density differences: Exploring regional resurfacing, secondary crater populations, and crater saturation equilibrium on the Moon. *Planet Space Sci*, 162: 41–51
- Redmon J, Farhadi A. 2017. YOLO9000: Better, faster, stronger. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 7263–7271
- Redmon J, Divvala S, Girshick R, Farhadi A. 2016. You only look once: Unified, real-time object detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 779–788
- Ren S, He K, Girshick R, Sun J. 2015. Faster R-CNN: Towards real-time object detection with region proposal networks. *Adv Neural Inform Proc Syst*, 28, DOI: 10.48550/arXiv.1506.01497
- Roatsch T, Kersten E, Matz K D, Preusker F, Scholten F, Jaumann R, Raymond C A, Russell C T. 2016. High-resolution Ceres high altitude mapping orbit Atlas derived from Dawn framing camera images. *Planet Space Sci*, 129: 103–107
- Roatsch T, Kersten E, Matz K D, Preusker F, Scholten F, Jaumann R, Raymond C A, Russell C T. 2017. High-resolution Ceres low altitude mapping orbit Atlas derived from Dawn framing camera images. *Planet Space Sci*, 140: 74–79
- Robbins S J. 2019. A new global database of Lunar impact craters >1–2 km: 1. Crater locations and sizes, comparisons with published databases, and global analysis. *J Geophys Res-Planets*, 124: 871–892
- Robbins S J, Hynek B M. 2012. A new global database of Mars impact craters 1 km: 1. Database creation, properties, and parameters. *J Geophys Res*, 117: 2011JE003966
- Ronneberger O, Fischer P, Brox T. 2015. U-net: Convolutional networks for biomedical image segmentation. Munich: Proceedings of Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference. 234–241
- Salamunićar G, Lončarić S, Pina P, Bandeira L, Saraiva J. 2011. MA130301GT catalogue of Martian impact craters and advanced evaluation of crater detection algorithms using diverse topography and image datasets. *Planet Space Sci*, 59: 111–131
- Salese F, McMahon W J, Balme M R, Ansan V, Davis J M, Kleinhans M G. 2020. Sustained fluvial deposition recorded in Mars' Noachian stratigraphic record. *Nat Commun*, 11: 2067
- Sawabe Y, Matsunaga T, Rokugawa S. 2005. Automatic crater detection algorithm for the Lunar surface using multiple approaches. *J Remote Sens Soc Japan*, 25: 157–168
- Sawabe Y, Matsunaga T, Rokugawa S. 2006. Automated detection and classification of Lunar craters using multiple approaches. *Adv Space Res*, 37: 21–27
- Silburt A, Ali-Dib M, Zhu C, Jackson A, Valencia D, Kissin Y, Tamayo D, Menou K. 2019. Lunar crater identification via deep learning. *Icarus*, 317: 27–38
- Smith D E, Zuber M T, Neumann G A, Lemoine F G. 1997. Topography of the Moon from the Clementine lidar. *J Geophys Res*, 102: 1591–1611
- Smith D E, Viswanathan V, Mazarico E, Goossens S, Head J W, Neumann G A, Zuber M T. 2022. The contribution of small impact craters to Lunar polar wander. *Planet Sci J*, 3: 217
- Speyerer E J, Robinson M S, Denevi B W, LROC Science Team. 2011. Lunar reconnaissance orbiter camera global morphological map of the Moon. In: Proceedings of 42nd Annual Lunar and Planetary Science Conference. (1608): 2387
- Stepinski T F, Mendenhall M P, Bue B D. 2009. Machine cataloging of impact craters on Mars. *Icarus*, 203: 77–87
- Sugiyama T, Abe K. 1997. Edge feature analysis by a vectorized feature extractor for multiple edges. *Syst Comp Jpn*, 28: 20–29
- Sun K, Xiao B, Liu D, Wang J. 2019. Deep high-resolution representation learning for human pose estimation. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 5693–5703
- Tanaka K L. 1986. The stratigraphy of Mars. *J Geophys Res*, 91: E139–E158
- Tewari A, Verma V, Srivastava P, Jain V, Khanna N. 2022. Automated crater detection from co-registered optical images, elevation maps and slope maps using deep learning. *Planet Space Sci*, 218: 105500
- Thomas R J, Rothery D A, Conway S J, Anand M. 2015. Explosive volcanism in complex impact craters on Mercury and the Moon: Influence of tectonic regime on depth of magmatic intrusion. *Earth Planet Sci Lett*, 431: 164–172
- Tian Z, Shen C, Chen H, He T. 2019. FCOS: Fully convolutional one-stage object detection. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 9627–9636
- Tissainayagam P, Suter D. 2004. Assessing the performance of corner detectors for point feature tracking applications. *Image Vision Computing*, 22: 663–679
- Trask N J, Guest J E. 1975. Preliminary geologic terrain map of Mercury. *J Geophys Res*, 80: 2461–2477
- Urbach E R, Stepinski T F. 2009. Automatic detection of sub-km craters in high resolution planetary images. *Planet Space Sci*, 57: 880–887
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N,

- Kaiser L, Polosukhin I. 2017. Attention is all you need. *Adv Neural Inform Proc Syst*, 30
- Viola P, Jones M. 2001. Rapid object detection using a boosted cascade of simple features. In: *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, 1: 1-1
- Wang C Y, Bochkovskiy A, Liao H Y M. 2023. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 7464-7475
- Wang H, Jiang J, Zhang G. 2018. CraterIDNet: An end-to-end fully convolutional neural network for crater detection and identification in remotely sensed planetary images. *Remote Sens*, 10: 1067
- Wang J, Cheng W, Zhou C. 2015. A Chang'E-1 global catalog of Lunar impact craters. *Planet Space Sci*, 112: 42-45
- Wang S, Li W. 2021. GeoAI in terrain analysis: Enabling multi-source deep learning and data fusion for natural feature detection. *Comput Environ Urban Syst*, 90: 101715
- Wang Y W, Qin C Z, Cheng W M, Zhu A X, Wang Y J, Zhu L J. 2022. Automatic crater detection by training random forest classifiers with legacy crater map and spatial structural information derived from digital terrain analysis. *Ann Am Assoc Geographers*, 112: 1328-1349
- Wang Y, Wu B. 2019. Active machine learning approach for crater detection from planetary imagery and digital elevation models. *IEEE Trans Geosci Remote Sens*, 57: 5777-5789
- Wang Y, Wu B, Xue H, Li X, Ma J. 2021. An improved global catalog of Lunar impact craters (≥ 1 km) with 3D morphometric information and updates on global crater analysis. *J Geophys Res-Planets*, 126: e2020JE006728
- Wu B, Dong J, Wang Y, Rao W, Sun Z, Li Z, Tan Z, Chen Z, Wang C, Liu W C, Chen L, Zhu J M, Li H L. 2022. Landing site selection and characterization of Tianwen-1 (Zhurong rover) on Mars. *J Geophys Res-Planets*, 127: e2021JE007137
- Wu Y, Wan G, Liu L, Jia Y, Wei Z, Wang S. 2022. Fast and accurate crater detection on Martian surface using SUN et 3+. In: *Proceedings of 2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC)*, 6: 683-687
- Xie Y, Tang G, Yan S, Lin H. 2013. Crater detection using the morphological characteristics of Chang'E-1 digital elevation models. *IEEE Geosci Remote Sens Lett*, 10: 885-889
- Yang C, Zhao H, Bruzzone L, Benediktsson J A, Liang Y, Liu B, Zeng X, Guan R, Li C, Ouyang Z. 2020. Lunar impact crater identification and age estimation with Chang'E data by deep and transfer learning. *Nat Commun*, 11: 6358
- Yang H, Xu X, Ma Y, Xu Y, Liu S. 2021. CraterdaNet: A convolutional neural network for small-scale crater detection via synthetic-to-real domain adaptation. *IEEE Trans Geosci Remote Sens*, 60: 1-12
- Yang J, Kang Z. 2019. Bayesian network-based extraction of Lunar impact craters from optical images and DEM data. *Adv Space Res*, 63: 3721-3737
- Yang Q, Wei X, Wang B, Hua X S, Zhang L. 2021. Interactive self-training with mean teachers for semi-supervised object detection. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 5941-5950
- Yang S, Cai Z. 2021. High-resolution feature pyramid network for automatic crater detection on Mars. *IEEE Trans Geosci Remote Sensing*, 60: 1-12
- Yang S, Cai Z. 2022. Progressive domain adaptive network for crater detection. *IEEE Trans Geosci Remote Sens*, 60: 1-12
- Yue S, He L, Wen Y, Lu G, Lin H. 2013. Shape characteristics-based extraction of Lunar impact craters: Using DEM from the Chang'E-1 satellite as a data source. *Ann GIS*, 19: 53-62
- Zang S, Mu L, Xian L, Zhang W. 2021. Semi-supervised deep learning for Lunar crater detection using CE-2 DOM. *Remote Sens*, 13: 2819
- Zeilhofer M F, Barlow N G. 2021. The morphologic and morphometric characteristics of craters on Ceres and implications for the crust. *Icarus*, 368: 114428
- Zhang Z, Xu Y, Song J, Zhou Q, Rasol J, Ma L. 2023. Planet craters detection based on unsupervised domain adaptation. *IEEE Trans Aerosp Electron Syst*, 1-13
- Zhou Z, Rahman Siddiquee M M, Tajbakhsh N, Liang J. 2018. UNet++: A nested U-Net architecture for medical image segmentation. Granada: *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018*. 3-11
- Zhu J, Liang J, Tian X. 2023. Lunar impact crater detection based on YOLO v7 using multi-source data. In: *Proceedings of 2023 IEEE International Conference on Control, Electronics and Computer Technology (ICCECT)*. 901-905
- Zhu L, Geng X, Li Z, Liu C. 2021. Improving YOLOv5 with attention mechanism for detecting boulders from planetary images. *Remote Sens*, 13: 3776

(责任编辑: 惠鹤九)