

# 基于无锚深度卷积神经网络的月表小尺度 撞击坑自动识别

张梓璇<sup>1,2,3</sup>, 杨俊涛<sup>2,3</sup>, 李林<sup>3</sup>, 张硕伟<sup>4</sup>, 杨子毅<sup>2</sup>, 马月超<sup>3</sup>

1. 中国地质大学(武汉)资源学院, 武汉 430074;

2. 山东科技大学 测绘与空间信息学院, 青岛 266590;

3. 北京控制工程研究所 空间光电测量与感知实验室, 北京 100190;

4. 山东科技大学 地球科学与工程学院, 青岛 266590

**摘要:** 撞击坑作为月球表面上最典型和最常见地貌单元, 其形态特征和空间分布记录着月球的演化历史、气候形成以及月球表面年代。由于撞击坑边缘模糊、撞击坑嵌套等现象, 导致撞击坑 (尤其是小尺度撞击坑) 自动识别仍存在识别精度不高、大尺度撞击坑中的小尺度撞击坑难以不易识别等问题。因此, 针对小尺度撞击坑数量众多且不易识别, 以及嵌套撞击坑识别等问题, 本文提出了一种基于迁移学习策略的无锚深度卷积神经网络月表小尺度撞击坑自动识别方法, 来自动定位和识别撞击坑。该方法在堆叠沙漏网络生成的高分辨率特征图上直接回归出撞击坑的中心及其大小, 并且无需使用非极大值抑制等后处理操作, 实现了不同类型撞击坑的自动识别。同时, 采用迁移学习的思想进行训练, 为模型训练赋予一定的优化参数, 使其并非从头开始训练, 从而使模型具备更高的可靠性和稳健性。文中选择虹湾和风暴洋月表地区的影像进行实验验证, 并与其现有人工标注的 Robbins 撞击坑数据库进行定量与定性评估, 结果表明本文设计的自动识别模型能有效地实现撞击坑提取, 且一定程度上解决了嵌套撞击坑中小尺度撞击坑的识别。

**关键词:** 撞击坑提取, 智能识别, 深度学习, 目标识别, 虹湾地区, 风暴洋地区

**中图分类号:** P691/P2

**引用格式:** 张梓璇, 杨俊涛, 李林, 张硕伟, 杨子毅, 马月超. 2025. 基于无锚深度卷积神经网络的月表小尺度撞击坑自动识别. 遥感学报, 29(2): 429-441

Zhang Z X, Yang J T, Li L, Zhang S W, Yang Z Y and Ma Y C. 2025. Automatic anchor-free convolutional neural network method for recognizing small-scale lunar impact craters. National Remote Sensing Bulletin, 29(2): 429-441[DOI:10.11834/jrs.20243206]

## 1 引言

撞击坑作为月表最主要的构造单元和地貌形态, 其形态和空间分布特征不仅是描述月球表面形态特征的明确标志, 也是反映月表地质年龄以及进一步推演月球演化历史的重要因素 (Cohen 和 Ding, 2014)。月表撞击坑按照直径大小分为小尺度撞击坑和中一大尺度撞击坑, 其中前者是指直径 < 1 km 的撞击坑, 后者指直径 ≥ 1 km 的撞击坑 (McEwen 和 Bierhaus, 2006)。撞击坑 (尤其是小尺度撞击坑) 的空间分布特征揭示并反映了行星

表面的相对和绝对地质年龄, 因为月球上小尺度撞击坑的发生频率要远大于大中尺度撞击坑, 可以提供更加丰富的撞击信息。此外, 月球撞击坑的识别也有利于着陆器和巡视器的精确导航和安全避障 (杜省等, 2025)。因此, 月表撞击坑的识别一直是国内外研究的热点话题。

撞击坑识别的方法自发展至今, 从早期的天文望远镜人工识别, 到利用光学遥感影像和数字高程模型等数据的人工识别, 再到自动识别获取 (张诚和陈建平, 2019), 逐步为编制精细化的全月地貌图提供了必不可少的基础性资料。截止目

收稿日期: 2023-06-14; 预印本: 2024-01-18

基金项目: 北京控制工程研究所空间光电测量与感知实验室开放基金资助 (编号: LabSOMP-2023-08)

第一作者简介: 张梓璇, 研究方向为月表环形构造提取与分析。E-mail: 17686101523@163.com

通信作者简介: 杨俊涛, 研究方向为激光雷达技术与应用、农业遥感、月球与行星遥感。E-mail: jtyang@sdu.edu.cn

前, 撞击坑自动识别方法可以分为以下3类: 基于非监督的方法、基于机器学习的方法以及基于深度学习的方法。基于非监督的方法一般在提取撞击坑边缘信息后, 利用模型拟合的方式实现自动提取过程。Kang等(2015)对由嫦娥卫星获取的立体相机图像基于随机样本一致性RANSAC (RANdom Samples Consensus) 技术进行撞击坑边缘拟合, 初步实现撞击坑自动识别, 使用DEM数据对错误撞击坑边缘去除提高识别精度。张雯(2017)利用月表DEM数据并且根据撞击坑自身具有的洼地特征, 使用洼地处理法和最大类间方差实现了撞击坑识别。这类方法往往自动化程度高, 但更适合对大尺度撞击坑的自动识别。随着计算机运算能力的提升, 大量国内外学者开始关注利用机器学习和深度学习进行撞击坑自动识别的研究工作(赵丹冬, 2022)。基于机器学习的方法是借鉴人脸识别等领域的方法, 需要人为设计特征描述子对撞击坑几何形态和纹理特征进行定量化编码(如HOG特征, Harr-like特征等), 然后利用带有标签的训练数据学习分类器, 进行撞击坑的自动定位和识别。Bandeira等(2014)使用基于数学形态学的多尺度形态滤波器提取撞击坑的纹理特征(Harr-like特征), 之后将纹理特征作为训练数据的标签, 采用支持向量机(SVM)来达到识别撞击坑的目的。Di等(2014)使用火星DEM数据提取Harr-like特征、缩放Harr-like特征以及LBP特征后, 将3类特征联合作为训练数据标签, 选用自适应增强算法识别出撞击坑, 最后利用局部地形分析和CHT实现撞击坑圆形边缘拟合。Kang等(2019)基于影像中撞击坑的HOG特征训练, 使用支持向量机(SVM)分类器获取小尺度撞击坑来更新样本集。这类方法与基于非监督的方法相比, 在识别小尺度撞击坑方面性能有很大提升, 而且用于定量化描述撞击坑的特征描述子具有较强的可解释性, 但是方法的性能受制于特征描述子的区分能力。

近些年, 深度学习由于其能够自主学习高描述力的特征表达, 在诸多领域取得了出色的性能。因此, 一些研究也着眼于构建端到端的撞击坑自动识别框架: 崔兴立等(2021)采用DEM数据, 基于卷积神经网络算法的YOLO V5目标检测系统, 以专家标记的撞击坑系统作为辅助, 自动提取月球南极-艾特肯盆地的小型撞击坑; Silbur等

(2019)使用CNNs网络对月球DEM数据处理后, 确定了撞击坑位置和大小且识别精度较好; Yang和Kang(2019)使用深度学习的迁移学习法进行撞击坑的识别, 识别数量比初步识别的数量多了十几倍; 赵丹冬(2022)以特征放大策略对月表小撞击坑进行特征提取, 基于R-FCN对月球小型撞击坑检测并对撞击坑定量与定性评价; 陈子丹(2021)根据撞击坑引起的重力异常构建撞击坑训练数据集, 采用U-Net卷积神经网络对数据集进行训练, 最后根据异常图中相邻异常值的变化趋势来自定位月表撞击坑的轮廓和位置。

虽然诸多撞击坑提取方法被有效地提出, 但是在现有方法中撞击坑(特别是小尺度撞击坑)的自动识别仍然面临如下挑战: 一是撞击坑在光学图像中缺乏明显的形态特征。当前大部分方法都是基于其在图像中有着明显的圆形边缘信息, 但风化和地质变化等因素会使其圆形边缘变得模糊; 二是撞击坑数量众多且大小差异显著, 造成撞击坑出现嵌套叠加现象, 进一步加剧了撞击坑的识别难度。针对以上问题, 本研究拟以小尺度撞击坑为探究对象, 采用迁移学习思想提出一种基于CenterNet网络自动识别月表撞击坑的研究方法, 探究小尺度撞击坑的特征提取和识别, 以期自动识别撞击坑技术提供科学依据。

## 2 无锚深度卷积神经网络识别模型与评价方法

本研究采用的基于无锚深度卷积神经网络模型, 是一种单阶段过程的目标检测方法。单阶段过程的目标检测方法首先取消了对感兴趣区域(ROI)的提取, 直接对产生的候选框进行分类和回归(Duan等, 2019), 以达到目标识别的目的。现有的单阶段目标检测方法, 如YOLOv2、CornerNet(Redmon和Farhadi, 2017; Law和Deng, 2018)等。对于双阶段目标检测方法而言, 需要预先定义锚框, 并在预测过程中通过滑动窗口依次产生所有可能的候选框, 在后续的后处理过程中使用非极大值抑制等操作锁定最优候选框。而本实验采用的基于无锚深度卷积神经网络模型, 取消了预定义锚框, 即使用无锚目标检测。无锚目标检测不会产生大量不符合目标条件的候选框, 无需在后处理中做非极大值抑制操作, 提高了模型的预测速率, 并且在模型生成的特征图中直接拟合

回归撞击坑的中心位置和大小, 解决大尺度撞击坑中嵌套的小尺度撞击坑的稳健识别。

同时, 为解决撞击坑圆形边缘不明显问题, 本研究以堆叠沙漏网络 (Stacked Hourglass) 作为

骨干网络, 有效地聚合多尺度视觉信息, 以提高其表达能力。图1为本研究提出的月表小尺度撞击坑自动识别网络模型的流程图。

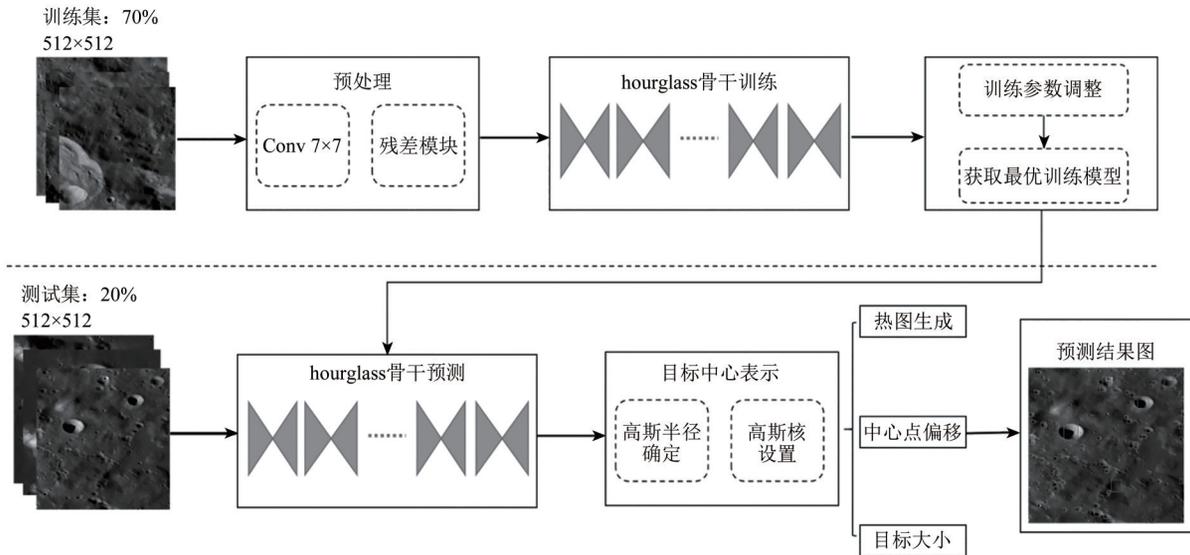


图1 Centernet网络结构图

Fig. 1 Centernet network structure diagram

### 2.1 CenterNet网络结构

CenterNet网络结构如图1所示, 主要包括3个部分: (1) 图像预处理, 对图像预处理是通过一个步长为2的7×7的卷积和一个步长为2的残差网络, 将图像的宽高分别压缩至原来的1/4; (2) 骨干网络 (backbone), 本论文中以hourglass作为主要网络基准, 并选用resnet-50网络来与其作比较; (3) 结果预测, 包含3个分支, 分别为热图、中心

点偏移以及目标大小。

### 2.2 骨干网络

本文选用的堆叠沙漏网络 (stacked hourglass) 形似沙漏, 多个沙漏模块以端到端的方式组成。堆叠沙漏网络是由多个hourglass网络组成, 每层hourglass网络都可以获得热图, 每层的热图直接传递给下一层hourglass网络, 由此实现端到端的传递。图2为本文选用的堆叠沙漏网络结构图。

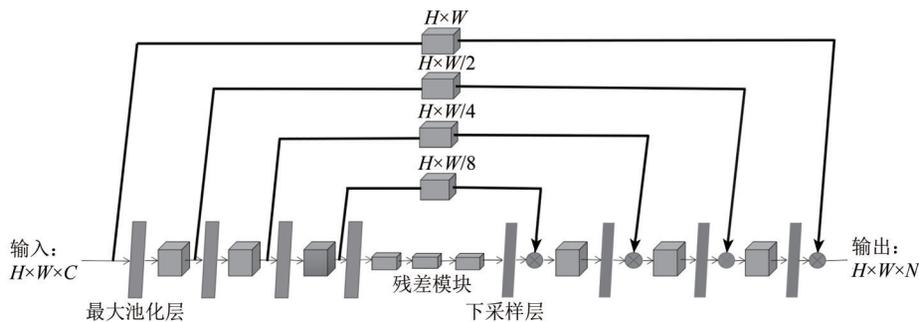


图2 Hourglass网络结构图

Fig. 2 Hourglass network structure diagram

单层hourglass网络的主要流程为: 首先进行单个沙漏模块的下采样过程, 利用卷积和最大池化层将特征下降至低分辨率, 便于降低后续计算

复杂程度; 当分辨率达到最低时, 进行上采样过程, 采用最近邻插值法将低分辨率特征图上采样至较高分辨率特征图中; 最后, 通过3×3的卷积层

将特征压缩映射至256个通道的图像中。至此，在经过多个端到端的堆叠沙漏后获取高分辨率特征图。对高分辨率经过2个1×1卷积层操作后，获取热力图中心点预测。

### 2.3 基于迁移学习的多任务网络模型训练

网络训练。Centernet网络训练关键是直接在热图上进行撞击坑中心点的回归拟合，其中主要

依赖于高斯圆半径的获取与损失函数的计算。

高斯圆半径的确定主要依赖于撞击坑矩形框的宽高，设置人为标注矩形框与预测矩形框的交并比(IoU)，计算出3种情况半径：(1)预测矩形框中包含人为标注矩形框；(2)人为标注矩形框包含预测矩形框；(3)人为标注矩形框与预测矩形框相互重叠，取最小值为高斯核半径。图3为高斯圆半径计算的3种情况。

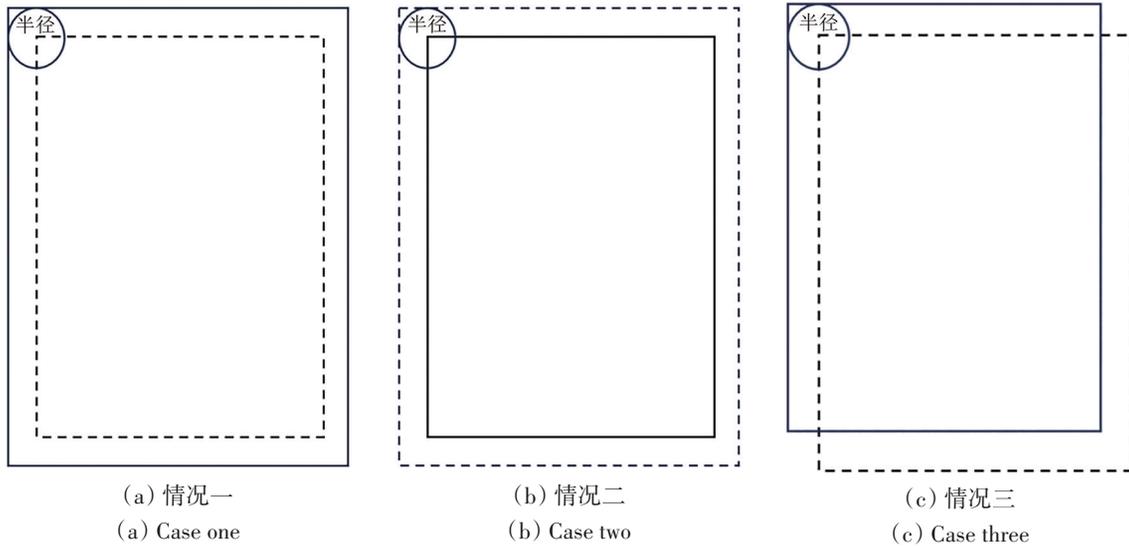


图3 高斯圆半径情况图

Fig. 3 Gaussian circle radius case diagram

对于撞击坑识别而言，计算出的高斯圆半径所在范围内，不能仅仅只在中心位置设置标签为1在其余部分设为0，而是在其半径范围内设置一个高斯分布数值，依次递减。高斯核函数 $Y_{x,y}$ 的计算公式如下：

$$Y_{x,y} = \exp\left(-\frac{(x - \hat{x})^2 + (y - \hat{y})^2}{2\sigma^2}\right) \quad (1)$$

式中， $x, y$ 为预测撞击坑坐标， $(\hat{x}, \hat{y})$ 为人为标注的撞击坑坐标，参数 $\sigma$ 设为1/3，代表着撞击坑尺寸标准差。

在整个CenterNet网络中，损失函数包含3个部分：热图中撞击坑中心点损失( $L_{\text{keypoint}}$ )、撞击坑中心点偏移损失( $L_{\text{off}}$ )以及撞击坑大小损失函数

( $L_{\text{size}}$ )。计算公式如下：

$$L_{\text{det}} = L_{\text{keypoint}} + \lambda_{\text{size}} L_{\text{size}} + \lambda_{\text{off}} L_{\text{off}} \quad (2)$$

式中， $L_{\text{det}}$ 为总损失量， $L_{\text{keypoint}}$ 为撞击坑中心点损失， $L_{\text{size}}$ 为撞击坑大小损失， $L_{\text{off}}$ 为撞击坑中心点偏移损失， $\lambda_{\text{size}}$ 和 $\lambda_{\text{off}}$ 分别设置为0.1和1。

撞击坑中心点损失(focal loss)：在进行撞击坑目标检测时，只需要检测出撞击坑中心点所在的局部范围，不需要完全确定其具体位置，即可自动识别撞击坑。在生成高斯分布热图中，使用撞击坑中心点检测函数不断优化中心点位置，通过对超参数的设置使其更加接近真实中心点坐标。图4为撞击坑中心点确定的实例。撞击坑中心点损失函数 $L_{\text{keypoint}}$ 如下：

$$L_{\text{keypoint}} = -\frac{1}{N} \sum_c \begin{cases} x = (1 - \hat{y}_c^{xy})^\alpha \log(\hat{y}_c^{xy}) & , \hat{y}_c^{xy} = 1 \\ y = (1 - \hat{y}_c^{xy})^\beta (\hat{y}_c^{xy})^\alpha \log(1 - \hat{y}_c^{xy}) & , \text{其他} \end{cases} \quad (3)$$

式中， $N$ 为总样本数， $\hat{y}_c^{xy}$ 表示在检测到第 $c$ 个撞击坑时其中心点 $(x, y)$ 在特征图上的预测值，取值范围为 $[0, 1]$ ， $y_c^{xy}$ 表示第 $c$ 个撞击坑时其中心点

$(x, y)$ 在特征图上的真实值， $\alpha, \beta$ 为模型中超参数，分别设置为2和4。

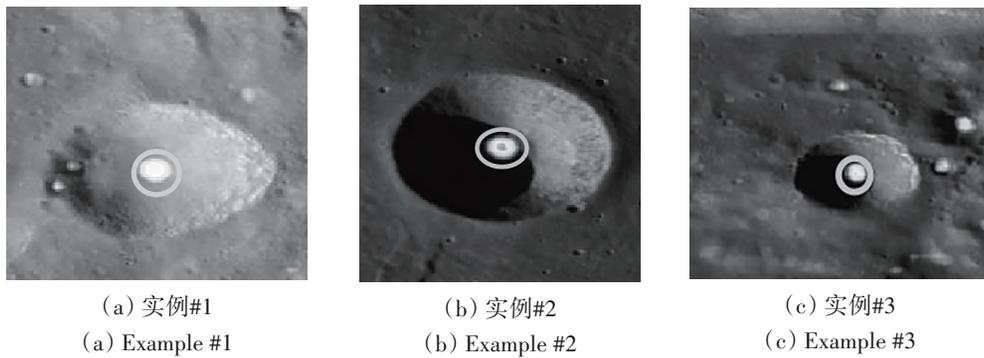


图4 撞击坑中心点确定  
Fig. 4 The determination of impact crater's center point

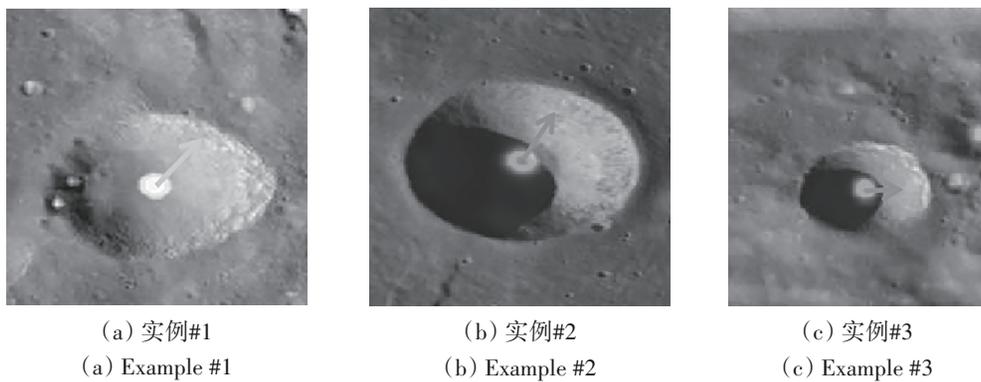


图5 撞击坑中心点偏移损失  
Fig. 5 Impact crater's center offset loss

撞击坑中心点偏移损失 (offset loss): 由于影像在经过网络过程中, 发生过多次上采样和下采样, 可能会导致目标点位置出现偏移。图5为中心点偏移损失的实例。撞击坑中心点偏置损失  $L_{\text{off}}$  可以调节中心点预测精度, 减少因采样过程在精度上的损失, 计算公式如下:

$$L_{\text{off}} = \frac{1}{N} \sum_p \left| \hat{O}_p - \left( \frac{p}{R} - \hat{p} \right) \right| \quad (4)$$

式中,  $N$ 为训练样本数量即图片数量,  $\hat{O}_p$ 为预测的偏移值,  $p$ 代表目标框中心点,  $R$ 代表下采样倍数,  $(\frac{p}{R} - \hat{p})$ 为实际偏移值, 通过 L1 损失函数进行计算。

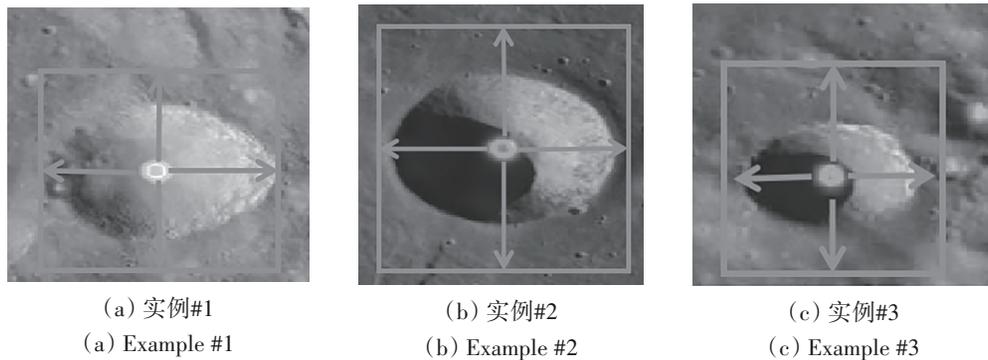


图6 撞击坑大小损失  
Fig. 6 Impact crater's size loss

撞击坑大小损失 (pull and push loss): 确定预测框的宽度和高度通过撞击坑大小损失函数实现。

撞击坑大小的确定通过对左上角坐标与右下角坐标的获得来确定预测框大小。对第  $k$  个撞击坑而

言, 其真实框其左上角与右下角坐标为  $(x_1^{(k)}, y_1^{(k)}, x_2^{(k)}, y_2^{(k)})$ , 其真实宽高为  $s_k = (x_2^{(k)} - x_1^{(k)}, y_2^{(k)} - y_1^{(k)})$ 。如果只考虑到关键点实际落入区域的输出特征图, 即  $\hat{S}_{p_k}$ , 则撞击坑大小损失  $L_{size}$  的函数计算公式如下:

$$L_{size} = \frac{1}{N} \sum_{k=1}^N \left| \hat{S}_{p_k} - s_k \right| \quad (5)$$

为了获取最优的网络模型参数和减少标注撞击坑训练样本的成本, 本文以迁移学习思想进行模型训练。迁移学习 (Transfer Learning) 目的是训练数据集较少时, 利用已有的具有相似识别特征的训练模型来对待识别数据集进行重新训练获取待识别数据的训练特征 (Yang 等, 2020)。与随机初始化训练模型不同, 本文利用前期工作得到的模型预训练权重对模型参数进行初始化, 并利用不同区域的待识别撞击坑训练样本对模型参数进行调整和优化, 最终获取适应不同地区的训练模型, 从而提高了模型的识别精确度和稳定性。

## 2.4 网络预测过程

在训练得到最优模型后, 将分辨率大小为  $512 \times 512$  的图像输入至模型中。由于选用数据范围较大, 因此将图像裁剪为  $512 \times 512$  分辨率大小后再进行训练 (Zhou 等, 2019)。在模型中, 图像首先进行 hourglass 骨干模型进行撞击坑的特征提取, 获得有着高分辨率特征图。之后高分辨率特征图放入由 3 个模块组成的反卷积中, 每个模块包含一个  $3 \times 3$  的卷积和反卷积。由其生成的特征图进行热图生成。在热图中主要进行撞击坑中心的确定及其大小即矩形宽高的确定, 其中撞击坑中心的确定是将获取的特征图通过一个  $3 \times 3$  的最大池化层进行撞击坑中心的筛选, 筛选后的撞击坑大小由预测框的 2 个角点进行表示, 即:  $(\hat{x}_i + \delta\hat{x}_i - \frac{\hat{w}_i}{2}, \hat{y}_i + \delta\hat{y}_i - \frac{\hat{h}_i}{2}, \hat{x}_i + \delta\hat{x}_i + \frac{\hat{w}_i}{2}, \hat{y}_i + \delta\hat{y}_i + \frac{\hat{h}_i}{2})$ , 式中,  $\hat{x}_i, \hat{y}_i$  为中心点预测值,  $\delta\hat{x}_i, \delta\hat{y}_i$  为预测值偏差,  $\hat{w}_i, \hat{h}_i$  为预测框的宽和高。此时, 准确识别出影像中撞击坑的位置及其大小。

## 2.5 评价指标

本文采用精确度 (Precision)、召回率 (Recall)、F1-score 以及 mAP 作为评价指标, 并绘制 ROC 曲线图和箱状图, 来定量分析模型识别结果的可靠

性和稳健性。

**精确度  $p$  (Precision):** 预测结果作为判断依据, 即图像中所有预测出的撞击坑中实际存在的撞击坑所占比例, 用于评估预测正例的准确度。**召回率  $r$  (Recall):** 以实际样本作为判断依据, 即图像中真实撞击坑被预测出来的撞击坑所占比例, 用于评估所有实际正例是否被预测出来的覆盖率占比多少。其计算公式如下:

$$p = \frac{TP}{TP + FP} \quad (6)$$

$$r = \frac{TP}{TP + FN} \quad (7)$$

式中, TP (True Positives) 代表真正例, 即预测到的撞击坑为真实撞击坑, FP (False Positives) 代表假正例, 即预测到的撞击坑并非为真实撞击坑, FN (False Negatives) 代表假负例, 即实际为撞击坑, 但并没有被检测到的撞击坑样本数量。

**F1-score:** 由于精确度和召回率的判别标准不一致, 在实验中会出现高精度度低召回率或低精确度高召回率。F1-score 是在两者之中找到一个平衡点, 使精确度和召回率在该点时均达到最高。通常 F1-score 的获取是通过设定阈值来达到, 其计算公式如下:

$$F1 - score = 2 \times \frac{p \times r}{p + r} \quad (8)$$

**平均精度 AP:** 计算每一类别的模型平均准确度, 即撞击坑获得的精确度和召回率绘成曲线后, 曲线与坐标轴包围的面积为 AP。**mAP:** 对所有类别的 AP 值求取平均。

## 3 研究区概况与数据处理

### 3.1 数据来源与研究区

本文利用美国国家航天局于 2009 年 6 月发射的月球勘测轨道器 (LRO) 搭载的广角相机拍摄的全月影像制作的正射影像进行模型验证。LRO 搭载了 3 台相机, 分别为两个窄角相机 (NACs) 和一个广角相机 (WAC), 其中前者可获取 5 km 条带内的分辨率为 0.5 m 全色图像, 而后者可以在 60 km 条带内获取 7 个色带分辨率为 100 m/pixel 的图像。在实验中, 本文选取虹湾区域附近 (月球  $15^\circ W - 35^\circ W, 25^\circ N - 50^\circ N$ ) 与风暴洋区域附近 (月球  $40^\circ W - 70^\circ W, 30^\circ N - 55^\circ N$ ) 作为研究区, 将虹湾地区与风暴洋地区的对应正射影像裁剪为

512×512大小。然后，将裁剪后的影像按照大型数据集 COCO (Common Objects in Context) 数据格式 (Lin 等, 2014) 组织和管理便于后续模型进行训

练和识别，并利用 Robbins 撞击坑数据库 (Robbins, 2019) 作为真值进行模型训练和测试。

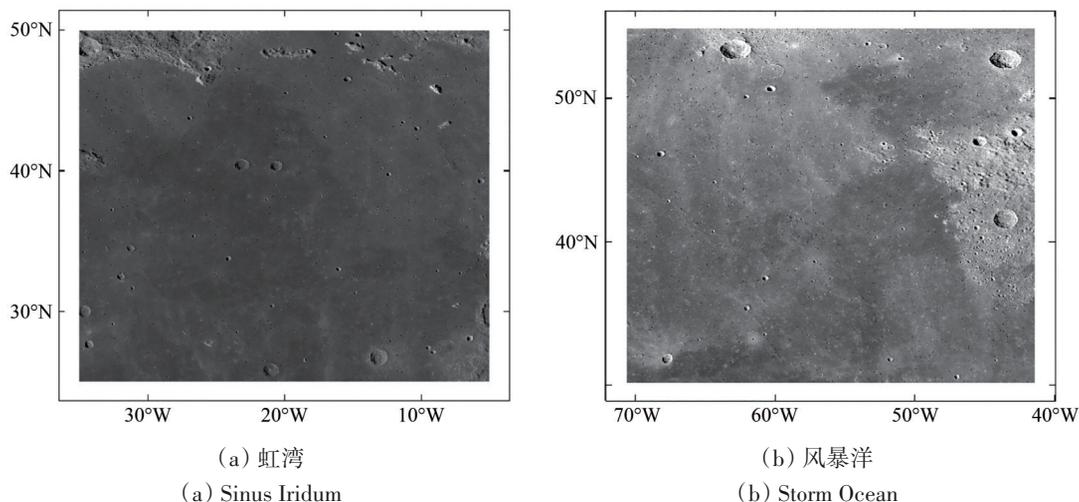


图7 虹湾和风暴洋研究区 WAC 正射影像

Fig. 7 WAC orthophotos of Sinus Iridum and Storm Ocean study area

### 3.2 训练过程

本实验选用 resnet-50 网络作为骨干网络与本文模型中的 hourglass 骨干网络进行对比实验，以体现本文模型中选用的 hourglass 骨干网络更适用于月表撞击坑的自动识别。

将撞击坑数据集随机划分为训练样本、验证样本和测试样本，其比例分别为 70%、10%、20%。将数据集放入 CenterNet 网络中，选用平台为 Pytorch 库构建的深度学习模块，以端到端的方式进行训练。在训练过程中，选择 Adam 作为优化器，epoch 总数设置为 100，前 50 次冻结骨干训练，后 50 次解冻骨干训练。训练期间冻结阶段一次训练随机选取的样本数设置为 32，解冻阶段一次训练随机选取的样本数设置为 16。

### 3.3 数据处理

精确度可以体现预测结果中正确预测的情况，召回率体现的是正确实例被准确预测出来的情况。但在模型评价时，不能单一考察模型的精确度或召回率，因此使用 F1-score 来平衡二者的值，使二者均达到最优。对于 F1-score 的确定本文通过设定阈值来确定其值，绘制 F1-score、精确度与召回率随阈值变化的曲线，取三者交点作为最优平衡点。随着阈值的不断增大，F1-score、精确度与

召回率变化趋势见图 8。可见，将 F1-score 的阈值设置为 0.34，此时，F1 值、精确度以及召回率达到最优平衡点。

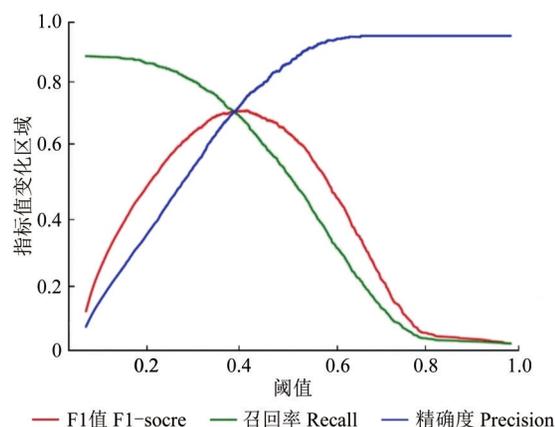


图8 F1-score、召回率和精确度三者随阈值变化图

Fig. 8 F1-score, recall and precision change with threshold value increasing

## 4 结果与分析

### 4.1 结果定量评价

虹湾地区和风暴洋地区数据分别通过 hourglass 和 resnet-50 骨干预测结果性能如表 1 所示。可见：在虹湾地区，使用 hourglass 骨干网络的精确度、召回率、F1 值分别是 75.97%、74.71%、75.08%；

在风暴洋地区,使用 hourglass 骨干网络的精确度、召回率、F1 值分别是 75.09%、72.20%、74.03%。仅由定量的评价指标来看,虹湾地区和风暴洋地区的精确度、召回率、F1 值均达到了 70% 以上,表示识别结果中正确识别原有撞击坑以及撞击坑中为实际撞击坑的比例均在 70% 以上。对虹湾地区和风暴洋地区 3 个指标进行比较,发现在虹湾地区模型自动识别出的撞击坑的出错率更少。对比两者输入模型的图像后得出以下分析:虹湾地区地形较虹湾地区平坦,撞击坑形态更好拟合,因此模型自动识别出错率较少。

由表 1 可见:使用 resnet-50 网络作为骨干网络时,预测结果的精确度、召回率、F1 值以及 mAP 情况。其中:虹湾地区的数据使用 hourglass 骨干网络时的精确度、召回率以及 F1 值比使用 resnet-50 为骨干网络约高 1.68%、0.79% 以及 1%;风暴洋地区的数据使用 hourglass 骨干网络时的精确度、召回率以及 F1 值较使用 resnet-50 网络为骨干时约高 1.43%、0.16% 以及 1%。通过两者差值的比较可以看出,在 hourglass 作为骨干网络时的无锚深度卷积神经网络模型有着更好的识别效果,比起 resnet-50 网络, hourglass 网络更好地提取撞击坑信息,在图像中识别出更多的撞击坑,以便于后续的撞击坑统计。

表 1 不同骨干网络识别性能表

Table 1 Performance of different backbone networks

位置	骨干网络	精确度	召回率	F1-score	mAP
虹湾地区	Hourglass	75.97	74.71	75.08	81.35
	Resnet-50	74.29	73.92	74.00	74.29
风暴洋地区	Hourglass	75.09	72.20	74.03	80.92
	Resnet-50	73.66	72.04	73.34	78.44

为了更加明显的展示不同骨干网络模型对撞击坑识别的差异,本文绘制了虹湾地区和风暴洋地区的影像数据中 ROC 曲线图,详见图 9。由于本文基于迁移学习思想,为体现迁移学习的优势,选取四种模型分别绘制其 ROC 曲线比较模型的优劣,分别为:未进行预训练的 hourglass 骨干模型、未进行预训练的 resnet-50 骨干模型、进行预训练 hourglass 骨干模型以及进行预训练 resnet-50 骨干模型。选用 ROC 曲线是为了表现模型识别实验区中撞击坑的正确性,即表现模型正确识别出真实

撞击坑的比率。因此,曲线越接近左上角表明模型预测出的撞击坑更加贴合真实撞击坑。由图中表现出的,以 hourglass 为骨干网络模型预测后的 ROC 曲线高于以 resnet-50 为骨干网络预测后的 ROC 曲线,展示出本实验采用以 hourglass 为骨干网络的无锚深度卷积神经网络模型对撞击坑的预测情况优于以 resnet-50 为骨干网络的智能识别模型,预测出的撞击坑与真实撞击坑重叠度大。由 ROC 曲线的表现情况,也验证了上一步中采用精确度、召回率以及 F1 值体现出的本实验模型有着更优的正确率。由此可以得出以 hourglass 为骨干网络模型的性能要总体高于以 resnet-50 为骨干网络的模型性能。

迁移学习的思想是将经过数据集训练过的模型作为本次实验的预权值后再次使用本次实验数据集进行数据训练,得到预测模型所需要的训练模型。进行迁移学习的目的是为了提提高模型识别的准确性以及稳定性,提高整体识别的精确度。该模型稳定性和精确性的提升,在绘制的 ROC 曲线图中可以更好的显示出来。分别比较不同骨干模型的 ROC 曲线后发现,加入预训练模型的 ROC 曲线高于未加入预训练模型的 ROC 曲线。其中最优的模型为本实验选用的加入预训练后的 hourglass 骨干网络的深度卷积神经网络模型,最次的模型为未使用预训练模型作为权值直接对数据集训练的 resnet-50 骨干网络的深度卷积神经网络模型。由此可以得出,本文增加的迁移学习思想即为训练数据加入预训练模型,可以有效的帮助模型更好地收敛并提高模型识别的性能。这一想法在本次实验中得到了基本验证,在后续的工作研究中也可以发挥更好的作用。

为展示模型在提取撞击坑数据中的稳健性和可靠性,本文将虹湾地区和风暴洋地区一定范围的数据分别随机采样 80%,并将抽样数据输入至模型进行预测,获得预测结果的评价指标,重复以上操作 10 次,记录每次的 F1-score,绘制成箱线图。在虹湾地区的数据中,以 hourglass 为骨干的 F1-score 最小值要比 resnet-50 为骨干的 F1-score 最大值大,整体水平要高。表明实验选用的模型在虹湾地区中的预测结果准确率较高,效果更好。在风暴洋地区的数据中, hourglass 为骨干以较小优势高于以 Resnet-50 为骨干。以上均可得出,以 hourglass 为骨干网络的智能提取能力以及

精确度较高。同时，也可以发现同一模型的识别性能也会有一定波动，原因可能是：(1) 随机采样的测试影像覆盖区域的地形与训练模型时所用的影像存在一定的差异，导致撞击坑在图像中显

示出的形态不同 (Ding 等, 2011); (2) Robbins 撞击坑数据库本身也存在不同程度的漏标注情况, 尤其是 1 km 左右的小尺度撞击坑。

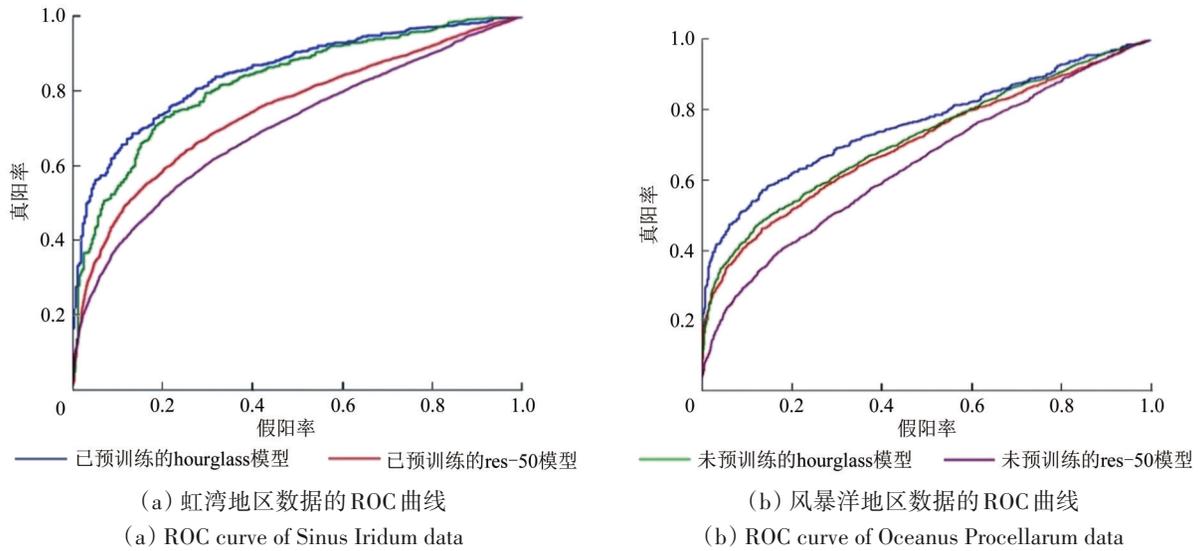


图 9 验证数据获取的 ROC 曲线  
Fig. 9 ROC curve obtained by test data

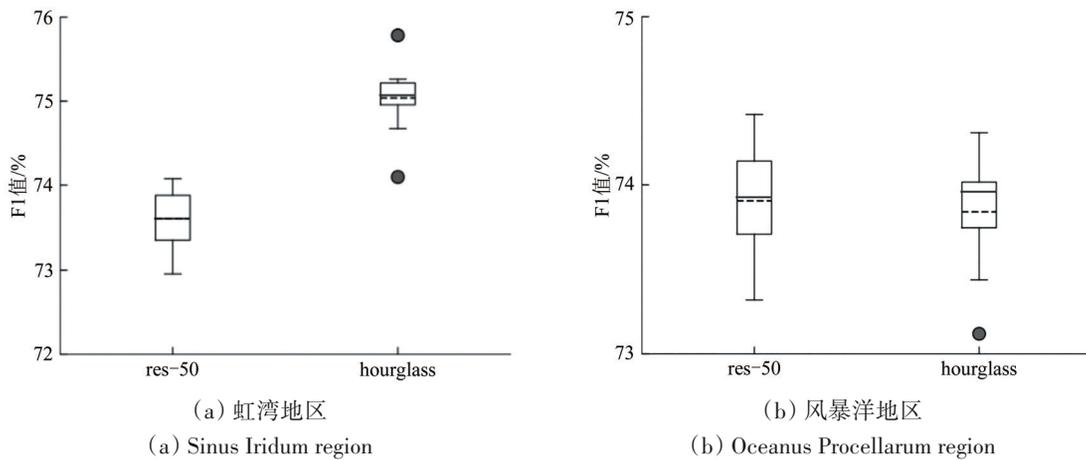


图 10 验证数据的 F1-score 箱状图  
Fig. 10 F1-score box plot on test data

本文对预测出的撞击坑数量进行了统计，并绘制了随撞击坑直径变化的柱状图来展示预测出的撞击坑数量。由于 Robbins 数据库中不存在直径 < 1 km 的小尺度撞击坑，为了便于图像的比较，将 Robbins 数据库中直径 < 1.05 km 的撞击坑近似为直径为 1 km 的撞击坑，并将撞击坑数量统计至 0.1—1 km。由图 11 可以获得，本文选用的模型对撞击坑预测出的数量平均高于实际标识出的撞击坑数量。尤其在直径 < 1 km 时，本文识别出的撞击坑数量明显多于数据库中直径近似为 1 km 的撞击坑数量。直

径 < 3 km，本文模型识别出的撞击坑数量明显高于实际标识撞击坑数量。但在直径为 1.5—2.0 km 的识别能力有待提高。这可能是由于实验区域地形等影响，但本文着重于研究小尺度撞击坑的识别并很好的实现了小尺度撞击坑识别。本实验中虹湾区域和风暴洋区域识别出的月表撞击坑数量在撞击坑直径 < 1 km 时相较 Robbins 数据库有着明显提升，说明本文模型可以很好的识别出月表小尺度撞击坑。

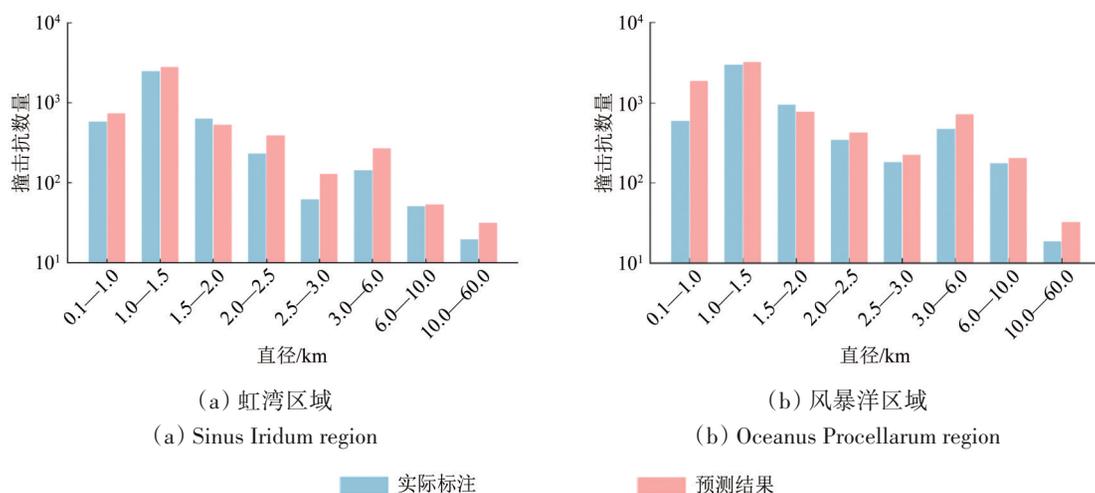


图 11 撞击坑预测数量与Robbins撞击坑数据库比较图

Fig. 11 The number of predicted impact craters compared with Robbins database

## 4.2 与其他方法对比

为了进一步评价提出方法的优势, 本文还与现有的其他方法 (Silburt等2019)、Yang等 (2020) 和Hu等 (2021)) 做了比较, 性能对比结果如表2所示。总体可见本文使用的方法要优于Silburt等 (2019) 和Hu等 (2021)。其中: 本文使用的方法精确度可以达到75.97%, 比Silburt等 (2019) 研究中精确度高4%左右, 比Hu等 (2021) 研究中精确度高5%左右。本文使用的方法F1-score达到75.08%, 比Silburt等 (2019) 和Hu等 (2021) 高出2%左右。虽然本文选用方法的召回率要明显低于Silburt等 (2019) 和Hu等 (2021) 研究结果, 但是召回率更高意味着Silburt等 (2019) 和Hu等 (2021) 研究主要是定位数据库标注的真实撞击坑, 减少漏检撞击坑数量, 而牺牲了撞击坑识别的准确性, 即精确度和召回率没有达到平衡。对于Yang等 (2020) 本文数据精确度和召回率较低, 究其原因初步推断是选用的深度卷积神经网络结构 (DeepCraters) 不适宜检测本文实验区的撞击坑。然而, 本文精确度75.97%和召回率75.08%, 说明二者处于平衡状态, 因此, 本文方法也更有优势。

## 4.3 结果定性评价

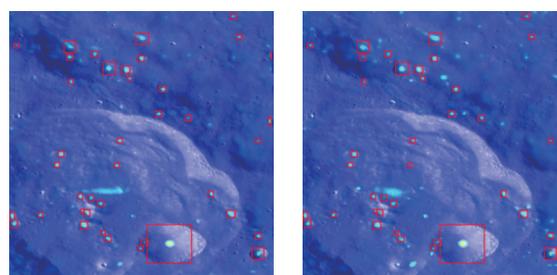
模型在训练过程中根据撞击坑中心点高斯核函数的概率生成热图, 结果见图12和图13。可见: 热力图中具有亮白色点, 同时蓝色亮点不明显的, 在模型中并没有将其作为撞击坑圈出, 主

要是因为在模型中预设了阈值范围, 排除了不明显的撞击坑, 从减少错识的现象, 以求更加准确的识别更多的撞击坑。

表 2 与其他已有方法对比

Table 2 Comparisons with other existing methods

方法	精确度	召回率	F1-score
Silburt等(2019)	61.94	87.32	72.47
Yang等(2020)	44.23	32.71	38.00
Hu等(2021)	60.37	92.74	73.13
本文方法	75.97	74.71	75.08



(a) 实例1 (hourglass骨干) (b) 实例2 (resnet-50骨干)  
(a) Example 1 (hourglass backbone) (b) Example 2 (resnet-50 backbone)

□ 撞击坑大小

图 12 虹湾地区数据的部分热力图

Fig. 12 Partial heatmaps of Sinus Iridum region

模型在预测过程中对影像中识别到的撞击坑生成矩形框, 结果见图14和图15。可见: 虹湾地区和风暴洋地区内大多数人工标识撞击坑被识别出来, 可以与真实撞击坑完全重叠。小部分识别

的撞击坑, 与真实撞击坑所在矩形框出现稍微错开的情况, 说明模型在确定撞击坑中心的能力仍有改进空间。图像中存在部分撞击坑识别误判情况。预测结果图中, 模型也可以将大型撞击坑中的小尺度撞击坑识别出来。

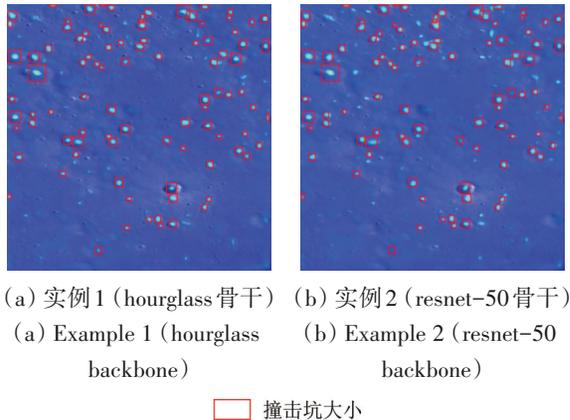


图 13 风暴洋地区数据的部分热力图

Fig. 13 Partial heatmaps of Oceanus Procellarum region

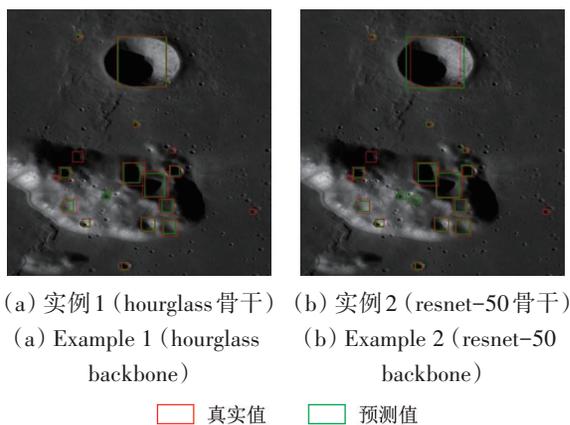


图 14 虹湾地区的预测图

Fig. 14 Forecast map of Sinus Iridum region

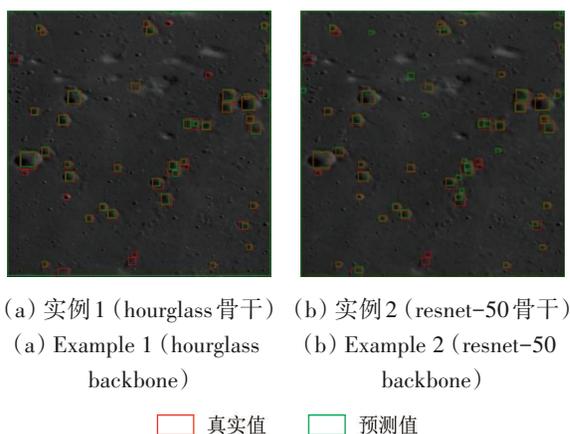


图 15 风暴洋地区的预测图

Fig. 15 Forecast chart of Oceanus Procellarum

## 5 结 论

本文针对月表小尺度撞击坑识别, 提出了一种基于迁移学习方法的深度学习网络智能识别方法。主要结论如下: 该方法优势在于使用迁移学习的思想让模型在一定的基础上进行模型训练, 从而使模型获得了更高的可靠性和有效性; 其次, 有效地解决了嵌套撞击坑中小尺度撞击坑的识别。在训练过程中对骨干 hourglass 网络取消了非极大值抑制, 从而获得较多的小尺度撞击坑; 最后研究表明, 本文方法在进行撞击坑识别时实现了召回率 74.71%, 精确度 75.97%, 相较于其他方法在识别准确度上有着明显优势, 并且在月表不同地区撞击坑的提取识别有着较高适应性。

本文对于月表撞击坑虽有着较好的识别, 但仍存在以下不足: 首先, 模型适用范围仍需提高。模型对虹湾地区和风暴洋地区的撞击坑识别时, 大部分地区识别效果较好, 但小部分地区如地形起伏大等识别效果差; 其次, 漏检问题虽有改善但仍需提高。在以后的研究工作中, 将针对以上问题对智能识别月表小型撞击坑模型进行改进和提高, 应扩大模型适用范围, 使其受地形和撞击坑形态影响减少。此外, 可充分利用不同地区撞击坑具有的相似性作为方法改进基础, 来降低月表撞击坑的漏检率。

## 参考文献 (References)

- Bandeira L, Machado M and Pina P. 2014. Automatic detection of sub-km craters on the Moon//45th Lunar and Planetary Science Conference. The Woodlands: [s.n.]
- Chen Z D. 2021. Research on Automatic Identification of Lunar Crater Gravity Anomaly Based on Convolutional Neural Network. Beijing: China University of Geosciences Beijing (陈子丹. 2021. 基于卷积神经网络的月球撞击坑重力异常自动识别研究. 北京: 中国地质大学(北京)) [DOI: 10.27493/d.cnki.gzdzy.2021.000733]
- Cohen J P and Ding W. 2014. Crater detection via genetic search methods to reduce image features. *Advances in Space Research*, 53 (12): 1768-1782 [DOI: 10.1016/j.asr.2013.05.010]
- Cui X L, Ding M and Wang G. 2021. Automated crater detection on the South Pole-Aitken Basin of the Moon and absolute model ages of mid-sized craters based on convolution neural network. *Journal of Nanjing University (Natural Science)*, 57(6): 905-915 (崔兴立, 丁恣, 王冠. 2021. 基于卷积神经网络的月球南极-艾特肯盆地撞击坑自动识别及中型撞击坑绝对模式年龄估算. 南京大

- 学学报(自然科学), 57(6): 905-915 [DOI: 10.13232/j.cnki.jnju.2021.06.001]
- Di K C, Li W, Yue Z Y, Sun Y W and Liu Y L. 2014. A machine learning approach to crater detection from topographic data. *Advances in Space Research*, 54(11): 2419-2429 [DOI: 10.1016/j.asr.2014.08.018]
- Ding W, Stepinski T F, Mu Y, Bandeira L, Ricardo R, Wu Y X, Lu Z Y, Cao T Y and Wu X D. 2011. Subkilometer crater discovery with boosting and transfer learning. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(4): 39 [DOI: 10.1145/1989734.1989743]
- Du X, Kang Z Z, Hu T, Xiao M and Li M. 2025. Application of topography analysis based on multi-source data in the construction of the International Lunar Research Station. *National Remote Sensing Bulletin*, 29(2): 442-459 (杜省, 康志忠, 胡腾, 肖萌, 李默. 2025. 基于多源数据的形貌分析在国际月球科研站建设中的应用. *遥感学报*, 29(2): 442-459) [DOI: 10.11834/jrs.20233011]
- Duan K W, Bai S, Xie L X, Qi H G, Huang Q M and Tian Q. 2019. CenterNet: keypoint triplets for object detection//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE: 6568-6577 [DOI: 10.1109/ICCV.2019.00667]
- Hu Y F, Xiao J, Liu L P, Zhang L and Wang Y. 2021. Detection of small impact craters via semantic segmenting lunar point clouds using deep learning network. *Remote Sensing*, 13(9): 1826 [DOI: 10.3390/rs13091826]
- Kang Z Z, Luo Z F, Hu T and Gamba P. 2015. Automatic extraction and identification of lunar impact craters based on optical data and DEMs acquired by the Chang'E satellites. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(10): 4751-4761 [DOI: 10.1109/jstars.2015.2481407]
- Kang Z Z, Wang X K, Hu T and Yang J T. 2019. Coarse-to-fine extraction of small-scale lunar impact craters from the CCD images of the Chang'E lunar orbiters. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1): 181-193 [DOI: 10.1109/tgrs.2018.2852717]
- Law H and Deng J. 2018. CornerNet: detecting objects as paired keypoints//The 15th European Conference on Computer Vision. Munich: Springer: 765-781 [DOI: 10.1007/978-3-030-01264-9\_45]
- Lin T Y, Maire M, Belongie S, Hays J, Perona P, Ramanan D, Dollár P and Zitnick C L. 2014. Microsoft COCO: common objects in context//The 13th European Conference on Computer Vision (ECCV). Zurich: Springer: 740-755 [DOI: 10.1007/978-3-319-10602-1\_48]
- McEwen A S and Bierhaus E B. 2006. The importance of secondary cratering to age constraints on planetary surfaces. *Annual Review of Earth and Planetary Sciences*, 34: 535-567 [DOI: 10.1146/annurev.earth.34.031405.125018]
- Redmon J and Farhadi A. 2017. YOLO9000: better, faster, stronger//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE: 6517-6525 [DOI: 10.1109/CVPR.2017.690]
- 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. *Journal of Geophysical Research: Planets*, 124(4): 871-892 [DOI: 10.1029/2018JE005592]
- Silburt A, Ali-Dib M, Zhu C C, Jackson A, Valencia D, Kissin Y, Tamayo D and Menou K. 2019. Lunar crater identification via deep learning. *Icarus*, 317: 27-38 [DOI: 10.1016/j.icarus.2018.06.022]
- Yang C, Zhao H S, Bruzzone L, Benediktsson J A, Liang Y C, Liu B, Zeng X G, Guan R C, Li C L and Ouyang Z Y. 2020. Lunar impact crater identification and age estimation with Chang'E data by deep and transfer learning. *Nature Communications*, 11(1): 6358 [DOI: 10.1038/S41467-020-20215-Y]
- Yang J T and Kang Z Z. 2019. Bayesian network-based extraction of lunar impact craters from optical images and DEM data. *Advances in Space Research*, 63(11): 3721-3737 [DOI: 10.1016/j.asr.2019.02.005]
- Zhang C and Chen J P. 2019. Advances in the study of automatic identification and classification of lunar impact craters. *Journal of Geology*, 43(3): 514-522 (张诚, 陈建平. 2019. 月球撞击坑自动识别和分类方法研究进展. *地质学刊*, 43(3): 514-522) [DOI: 10.3969/j.issn.1674-3636.2019.03.022]
- Zhang W. 2017. Research on Automatic Recognition and Spatial Differentiation of Lunar Impact Craters. Nanjing: Nanjing University of Information Science and Technology (张雯. 2017. 月球撞击坑的自动识别与空间分异研究. 南京: 南京信息工程大学)
- Zhao D D. 2022. Intelligent Identification and Spatial Distribution Characteristics Analysis of Small Craters in Lunar Landing Area. Changchun: Jilin University (赵丹冬. 2022. 月球着陆区小型撞击坑智能识别与空间分布特征分析. 长春: 吉林大学) [DOI: 10.27162/d.cnki.gjlin.2022.005459]
- Zhou X Y, Wang D Q and Krähenbühl P. 2019. Objects as points. arXiv:1904.07850

## Automatic anchor-free convolutional neural network method for recognizing small-scale lunar impact craters

ZHANG Zixuan<sup>1,2,3</sup>, YANG Juntao<sup>2,3</sup>, LI Lin<sup>3</sup>, ZHANG Shuwei<sup>4</sup>, YANG Ziyi<sup>2</sup>, MA Yuechao<sup>3</sup>

1. School of Earth Resources, China University of Geosciences, Wuhan 430074, China;

2. College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China;

3. Space Optoelectronic Measurement and Perception Lab., Beijing Institute of Control Engineering, Beijing 100190, China;

4. College of Earth Sciences and Engineering, Shandong University of Science and Technology, Qingdao 266590, China

**Abstract:** Impact craters are the most typical and common geomorphic units on the lunar surface. Their morphological and spatial distribution record the evolution history, climate formation, and surface age of the moon. Due to the impact crater's fuzzy edges and nested impact craters, the automatic recognition of impact craters (especially small-scale one) still faces problems such as low accuracy and difficulty in identifying small-scale within large-scale impact crater. Therefore, to address these, this paper proposes an automatic anchor-free convolutional neural network method based on transfer learning strategy to locate and identify small-scale lunar impact craters automatically.

Instead of using postprocessing operations such as nonmaximum suppression, the proposed method directly locates the centers of impact craters and regresses their sizes on the high-resolution feature map generated by the stacked hourglass network; thus, it realizes the automatic recognition of different types of impact craters. Moreover, the idea of transfer learning is used for training, not from scratch, so that the model has higher reliability and robustness.

This paper selects the Orthophoto image captured by the LRO WAC camera on the Lunar Reconnaissance Orbiter and the Robbins impact crater database in the Sinus Iridum and Oceanus Procellarum region to verify the reliability and robustness of the developed method. The method in this paper achieves a recall rate of up to 74.71% and an accuracy of up to 75.97%. Compared with other existing methods, the proposed method shows remarkable advantages in recognition accuracy and a high adaptability in extracting and identifying impact craters in different areas of the lunar surface. Comparing the performance and accuracy by drawing roc curves of different models reveals that transfer learning can effectively help the models converge better and improve the performance of model classification. The number of craters identified by the model is calculated and compared with the number of craters in the Robbins database. Results show that the proposed model can identify small-scale craters, and the number of craters identified in a certain diameter range is greater than that in the Robbins database. Therefore, the proposed model can provide a new tool for improving the lunar surface impact crater database.

The automatic recognition model in this paper can effectively extract impact craters and can to a certain extent solve the identification of small and medium-sized impact craters within nested impact craters. The key insight behind the developed method is to improve the model recognition accuracy based on transfer learning. The proposed method does not need the non-maximum suppression operation, which would effectively identify small and medium-sized ones within nested impact craters. Although the developed method shows a superior recognition performance for the lunar impact craters, the following shortcomings must be addressed. The generalization of the model still needs to be further improved. Therefore, future work will also make full use of the similarity of impact craters in different regions to reduce the missed detection rate of impact craters on the lunar surface.

**Key words:** impact crater extraction, intelligent recognition, deep learning, target recognition, Sinus Iridum region, Oceanus Procellarum region

**Supported by** Space Optoelectronic Measurement and Perception Lab., Beijing Institute of Control Engineering (No. LabSOMP-2023-08)