

ZHENG Yang, LI Dan, LIANG Zuzhong, CHENG Yong, ZHENG Zhongjie. Two-stage Contour Detection Method for Small-scale Disk-resolved Celestial Datasets (in Chinese). *Chinese Journal of Space Science*, 2025, 45(4): 1134–1148. CSTR:32142.14.cjss.2024-0086. DOI:10.11728/cjss2025.04.2024-0086

面向小规模面元天体数据集的 二阶段边缘检测方法*

郑 洋¹ 李 丹¹ 梁祖仲¹
程 永³ 郑中杰^{1,2}

1(广东海洋大学数学与计算机学院 湛江 524088)

2(暨南大学中法天体测量、动力学与空间科学联合研究实验室 广州 510632)

3(北京青苔数据科技有限公司 北京 100071)

摘 要 提出了一种面向小规模面元天体数据集的二阶段边缘检测方法. 第一阶段采用基于数字图像处理技术的窗口-边缘检测法进行初步边缘提取. 第二阶段则引入基于 ResNet 调整后的 LPC-ResNet 分类器, 用于补充第一阶段中可能遗漏的边缘点. 对新视野号远程勘测成像仪图像中的冥王星和冥卫一的边缘检测实验结果表明, 窗口-边缘检测法在精确率方面表现最佳, 即其去除非边缘点的能力最强, 但召回率较低. 通过引入 LPC-ResNet, 召回率与 F_1 分数均有提升, 从而增强了对边缘点的保留能力, 使提取的边缘更完整. 此外, 基于提取的边缘对冥王星和冥卫一进行的中心测量应用实验显示, 二阶段方法相较于单一的窗口-边缘检测法具有更高的检测精度, 证实了 LPC-ResNet 可有效改善窗口-边缘检测法的边缘提取结果.

关键词 边缘检测, ResNet, 新视野号远程勘测成像仪, 面元天体

中图分类号 P121

Two-stage Contour Detection Method for Small-scale Disk-resolved Celestial Datasets

ZHENG Yang¹ LI Dan¹ LIANG Zuzhong¹
CHENG Yong³ ZHENG Zhongjie^{1,2}

1(School of Mathematics and Computer, Guangdong Ocean University, Zhanjiang 524088)

2(Sino-French Joint Laboratory for Astrometry, Dynamics and Space Science, Jinan University, Guangzhou 510632)

3(Beijing Qingtai Data Technology Co., Ltd., Beijing 100071)

* 国家重点研发计划项目 (2022YFE0116800), 广东省自然科学基金项目 (2023A151501127) 和教育部科技发展中心产学研创新基金项目 (2020QT13) 共同资助

2024-07-03 收到原稿, 2025-04-15 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

Abstract In the astrometry of the disk resolved objects, contour detection acts as an important step, and it is equivalent to a binary classification process of classifying pixel points as contour points and non-contour points. For the purpose of automated extraction of hierarchical contour features, enhancement of contour detection precision, and accommodation of either limited-scale disk-resolved celestial datasets or preliminary-phase observational campaigns, a two-stage contour detection method for small-scale disk-resolved celestial datasets is proposed in this paper. In the first stage, a window contour detection method utilizing digital image processing techniques and comprising three operational steps: window extraction, window searching, and elliptical fitting, is employed to perform initial contour extraction. The second stage introduces an LPC-ResNet classifier, an adapted version of ResNet architecture, to supplement potential contour points missed by the window-contour detection method in the first stage. Experimental validation using New Horizons' Long-Range Reconnaissance Imager (LORRI) images of Pluto and its biggest satellite Charon demonstrates that the window-based method achieves optimal Precision, indicating its superior capability in filtering non-contour pixels, yet exhibits limited Recall, likely due to unintended exclusion of contour points during elliptical fitting in the window-contour detection method. After incorporating the LPC-ResNet classifier, both Recall and F_1 score are improved, enhancing the ability to retain contour points and resulting in more complete contour extraction. To further validate the role of LPC-ResNet classifier in refining detection outcomes, centroid measurement experiment of Pluto and Charon is conducted using the contours extracted by the two-stage detection method and the single window-contour detection method, using the ephemerides Plu060 as the reference. The results of the experiment demonstrate that the two-stage method reduces mean and standard deviation of the Observed-minus-Calculated (O-C) residuals in both x and y directions, which means that the two-stage method has higher detection precision compared to the single window-contour detection method, confirming that LPC-ResNet classifier can improve the contour extraction effect of the window-contour detection method.

Key words Contour detection, ResNet, New Horizons' Long Range Reconnaissance Imager, Disk resolved objects

0 引言

空间探测器技术的不断进步, 推动空间天体测量领域深入发展. 例如, 卡西尼号 (Cassini) 飞行器的光学成像科学子系统 (Imaging Science Subsystem, ISS), 以及新视野号 (New Horizons) 飞行器的远程勘测成像仪 (Long Range Reconnaissance Imager, LORRI) 所捕获的空间图像, 已经被应用于多项高精度天体测量的研究中. 具体而言, Cooper 等^[1]利用卡西尼号拍摄的图像对土星的卫星 Mimas, Tethys, Dione, Rhea, Iapetus 进行了位置测量与归算, Zhang 等^[2,3]和 Wang 等^[4]利用卡西尼号拍摄的图像对土星的卫星 Enceladus, Phoebe, Jauus, Epimetheus, Atlas, Prometheus, Pandora, Methone, Anthe 进行了位置测量与归算, Porter 和 Canup^[5]利用新视野号图像对冥王星 (Pluto) 的卫星 Hydra, Nix, Styx,

Kerberos 进行了轨道和质量的测定. 与地面观测相比, 空间图像的分辨率有显著提升, 提供了更为丰富的观测数据. 随着飞行器与观测目标接近至一定程度, 图像上的观测对象呈现出面元形状. 利用这类包含面元目标的图像, 可以进行目标边缘的提取. 边缘提取对于很多后续科学研究, 如天体的位置测量与归算, 以及天体物理参数的求解等是非常重要的.

边缘提取能有效提高面元天体位置测量的效率. 在进行位置测量^[1-5]前, 需要确保相机指向的准确性, 而一般的做法是利用星表 (例如 Gaia DR3)^[6]中的参考星进行匹配, 进而改善相机的指向精度和目标的位置测量精度^[1]. 然而在匹配过程中, 观测对象表面的大量凹凸不平或光照不均匀处会与参考星产生误匹配. 为了解决这个问题, 需要预先去除面元图像上的伪星像像素. 这一过程可以通过使用自动化边缘提取的方法来实现, 从而划定观测对象的表面区域, 并自

动去除出现在该区域内部的伪星像素。

观测目标的边缘提取结果可用于生成目标的位置测量结果(例如椭圆中心)。例如在 Cooper 等^[1]的工作中,针对面元图像可以采用 limb-fitting 的方式对观测对象进行定心测量,即通过提取面元对象的边缘,并进行椭圆拟合得到目标中心位置。

还可以利用边缘提取的结果进行观测目标的半径测定。例如, Nimmo 等^[7]利用新视野号的远程勘测成像仪图像进行了边缘提取,并基于这些结果计算出了冥王星及其卫星冥卫一卡戎(Charon)的半径。

自新视野号飞行器发射以来^[8],远程勘测成像仪设备获取了数量规模较小的冥王星及其卫星的空间面元图像^[9]。本文以这些图像为基础,进行了小规模的冥王星与冥卫一的面元图像数据集的边缘提取研究。在面元天体边缘提取的研究中,数字图像处理技术和机器学习方法是其中两种主要手段。数字图像处理方法以边缘检测算子、滤波和几何变换等技术为主。以太阳面元提取为例,Zharkova 等^[10]使用 Canny 算子对太阳面元的边缘进行检测,Yuan^[11]使用中值滤波、二值化与 Hough 变换等技术来确定太阳的边缘。然而,上述数字图像处理方法的研究对象是太阳,其表面相对冥王星等更为光滑,较少受到内部不均匀表面的影响。机器学习方法则是通过学习边缘像素的特征,对像素类型进行判别,最后只留下边缘像素,从而完善边缘的提取。例如,Zhang 等^[12]利用深度神经网络,Yang 等^[13]利用极限学习机提取了卡西尼号所拍摄图像的面元天体的边缘。上述机器学习方法需人工设计像素点特征,与残差网络^[14]等卷积神经网络相比,需要有一定的先验知识,且难以提取深层特征。然而,深度神经网络对计算资源与数据集规模均有一定要求。鉴于本文所使用的冥王星和冥卫一的面元图像数据集规模较小,仅依赖机器学习方法可能难以实现理想的效果。

为实现自动提取深层次的边缘特征,提高边缘检测的准确率,同时也能应对天体数据集规模较小或观测任务处于初期阶段的情况,本文提出一种将数字图像处理技术与卷积神经网络结合的、面向小规模面元天体数据集的二阶段边缘提取方法。其中,数字图像处理方法称为窗口-边缘检测法,该方法不依赖于数

据集与计算资源的规模;卷积神经网络则参考了 He 等^[14]提出的残差网络(Residual Neural Network, ResNet)。为适应小规模天体面元数据集,本文对网络结构进行调整,并将调整后的网络结构命名为 LPC-ResNet (Light Pluto Contour-ResNet)。为验证所提出方法的有效性,使用该方法对冥王星与冥卫一两面元天体的边缘进行提取,并与传统的 Roberts, Sobel, Prewitt 边缘检测算子以及 Zhang 等^[12]提出的深度神经网络进行边缘提取效果的比较分析。同时,为验证 LPC-ResNet 对边缘提取效果的改善作用,本文分别利用二阶段方法与单独的窗口-边缘检测法提取到的边缘点进行了椭圆拟合,计算出冥王星与冥卫一两面元天体的中心位置,并以 Plu060 历表中的理论位置作为参考,进行了测量结果的误差分析。

1 数据与方法

1.1 数据集

研究使用的图像全部下载自 PDS Image Atlas 网站^{*},共有 184 张,其中同时包含冥王星和冥卫一的图像有 129 张,仅含冥王星的有 32 张,仅含冥卫一的有 23 张。所有图像大小均为 1024×1024 pixel,并且已全部经过 New Horizons Science Operations Center (SOC) 管线的预处理^[15]。经过预处理后的图像被称为 Level 2 类型图像。同时,这些图像数据均为 1×1 binning mode 类型。

在本文的研究中,边缘的提取过程等价于对像素点进行二类分类的过程,即将每个像素点分类为边缘点(类别 1)与非边缘点(类别 0),最后再保留边缘点的过程。因此,需要将数据集中的边缘点与非边缘点进行标记,以便对每种方法的边缘提取结果进行评估。数据集的标记过程包括以下三个步骤。

步骤 1 使用 Canny 算子寻找灰度突变处,并生成二值图像 I 。其中,白色像素点为灰度突变处,其灰度值 $I(x, y) = 1$,而黑色像素点的灰度值 $I(x, y) = 0$ 。在这些初步提取的结果中,部分白色像素点属于天体的面元边界,是边缘点;另一部分来自面元内部的不均匀区域,是非边缘点。

步骤 2 对二值图像 I 中的白色像素点进行人工区分和类别标记,将外围边界的像素点标记为边缘点

^{*} <https://pds-imaging.jpl.nasa.gov/search/>

(类别 1), 内部不均匀区域的像素点标记为非边缘点 (类别 0). 为更清晰地展示边缘点, 将 Canny 算子滤波后的图像进行了颜色标记, 如图 1(b) 所示. 将图 1(b) 中蓝色标记的非边缘点去除后, 留下的点即为边缘点, 如图 1(c) 所示.

步骤 3 分别记录边缘点与非边缘点的坐标值, 以用于在后续完成 LPC-ResNet 网络的训练, 以及在每一种方法完成边缘提取后对比确认每个被提取的像素点是否为真实边缘点.

1.2 总体框架

提出的面向小规模天体面元数据集的二阶段边

缘提取方法的流程如图 2 所示. 为了提高结果图的清晰度, 进行相应的反色处理. 两个阶段的细节如下.

第一阶段, 执行窗口-边缘检测法, 提取初步边缘结果. 在输入原始图像后, 使用 Canny 算子进行预处理, 得到灰度突变处的像素点集合 F . 接着, 对 Canny 算子滤波的结果应用窗口-边缘检测法, 将提取的结果全部标记为边缘像素点 (类别 1), 并记录这些像素点的坐标形成集合 C ; 基于坐标记录结果, 在 Canny 算子提取的像素点集合 F 中排除类别 1 像素点后, 留下为非边缘点 (类别 0) 的像素点, 并记录其坐标形成集合 N . 可知 $F = C \cup N$.




图 1 数据集图像. (a) 原图像; (b) Canny 算子滤波图, 红色标记像素点为边缘点, 蓝色标记像素点为非边缘点; (c) 真实边缘图

Fig. 1 Dataset frame examples. (a) Original frame. (b) Canny operator filtered frame. The red marked pixels are contour points, and the blue marked pixels are non-contour points. (c) True contour frame




图 2 面向小规模天体面元数据集的二阶段边缘提取方法的流程. (a) 第一阶段, 通过执行窗口-边缘检测法获得初步的边缘. (b) 第二阶段, 使用 LPC-ResNet 分类器补充第一阶段遗漏的边缘点

Fig. 2 Process flowchart for a two-stage contour detection method for small-scale disk resolved celestial datasets.

(a) The first stage, where preliminary contours are obtained by performing the window-contour detection method.

(b) The second stage, where the LPC-ResNet classifier is used to supplement the contour points missed by the first stage

第二阶段, 使用 LPC-ResNet 作为分类器, 对第一阶段的结果进一步分类. 对于已经分类为边缘点 (类别 1) 的像素点, 保持其类别不变; 而对于分类为非边缘点 (类别 0) 的像素点, 使用这些像素点作为中心提取像素邻域图像数据, 并将其作为样本输入到已经训练好的 LPC-ResNet 模型中进行重新分类. 基于 LPC-ResNet 分类的结果集 L , 在窗口边缘-检测法的结果集 C 的基础上, 补充可能遗漏的边缘像素点, 最终输出更完整的边缘结果集 $R = C \cup L$.

1.3 窗口-边缘检测法

由 1.1 节可知, 用于测试边缘检测方法的面元数据集规模相当有限, 因此优先考虑使用数字图像处理技术提取边缘, 提出了一种具有鲁棒性的边缘提取算法, 即窗口-边缘检测法. 该方法避免了对数据集规模和计算资源的依赖, 并且易于扩展到其他种类的天体面元数据集中. 该方法包含窗口提取、窗口搜索、椭圆拟合三个步骤.

1.3.1 窗口提取

在窗口-边缘检测法的后续阶段, 需要在划定的窗口范围内进行边缘提取. 窗口范围由窗口提取步骤进行划分, 该步骤基于图像的边缘分布数据进行.

对使用 Canny 算子进行滤波后的图像 I 进行 X 和 Y 两个方向的投影运算, 分别得到 X 方向的边缘分布 $M(x)$, 以及 Y 方向的边缘分布 $M(y)$. $M(x)$ 和 $M(y)$ 的计算公式如下:

$$M(x) = \sum_y I(x, y), \quad (1)$$

$$M(y) = \sum_x I(x, y). \quad (2)$$

如图 3(a)(b) 所示, 以一幅同时包含冥王星和冥卫一的图像为例, 在经过投影运算后, 得到两个方向的边缘分布 $M(x)$ 和 $M(y)$ 的函数图像分别如图 3(c)(d) 所示. 假设观测目标的边缘分布 $M(x)$ 的最左和最右坐标点分别为 x_0 和 x_1 , $M(y)$ 的表示为 y_0 和 y_1 . 则窗口的范围可表示为 4 个顶点组成的坐标数组, 即 $\{(x_0, y_0), (x_0, y_1), (x_1, y_0), (x_1, y_1)\}$.

1.3.2 窗口搜索

经过窗口提取步骤后, 可使用坐标数组 $\{(x_0, y_0), (x_0, y_1), (x_1, y_0), (x_1, y_1)\}$ 表示窗口范围, 示例如图 4(a) 所示. 基于此范围, 程序执行窗口搜索步骤, 提取出初始的边缘.

窗口搜索的例子如图 4(b)~(e) 所示. 由图中可

见, 从窗口的上边界即 $y = y_0$ 开始, 程序依次从 4 个不同的边界出发, 进行由外到里的扫描. 只要每一行或每一列扫描到第一个白色像素点, 即停止扫描且标记该像素点为边缘像素点, 将其保留. 最终, 图 4(e) 给出了窗口搜索的结果, 即初步提取的边缘. 然而当前结果仍包含较多面元内部的细节, 这些细节可以被窗口-边缘搜索法的最后一步, 即椭圆拟合步骤去除.

1.3.3 椭圆拟合

冥王星和冥卫一的形状近似于椭圆, 这满足了使用椭圆拟合的前提条件. 为了充分地消除面元内部的细节, 椭圆拟合的执行次数不止一次. 在每次拟合之后, 都基于 Pukelsheim 提出的 3σ 原则^[16], 将拟合误差较大的像素点去除.

假设椭圆方程的两个焦点分别为 (x'_1, y'_1) , (x'_2, y'_2) , 样本像素点 (x_i, y_i) 数量为 n . 然后, 使用 L_i 来表示任意一个坐标点 (x_i, y_i) 到两个焦点之间距离的和, 可使用如下公式计算:

$$L_i = \sqrt{(x_i - x'_1)^2 + (y_i - y'_1)^2} + \sqrt{(x_i - x'_2)^2 + (y_i - y'_2)^2}. \quad (3)$$

根据椭圆方程的定义, 椭圆上任意一点到两个焦点之间的距离之和是一个常数, 假设该常数为 L_t , 则椭圆拟合的目标函数为

$$\sigma = \sqrt{\sum_{i=1}^n (L_i - L_t)^2 / (n - 1)}. \quad (4)$$

通过多次迭代的拟合过程, 并基于 3σ 原则不断剔除误差较大的点, 最终得到图 4(f) 所示结果, 可见面元的内部细节已经被剔除. 这使得非边缘点被排除, 提升了分类的精确率.

1.3.4 窗口-边缘检测法的局限性

在后续进行边缘提取的实验完成后, 将不同方法取得的精确率、召回率与 F_1 分数指标在 2.4.2 节给出, 指标结果给出了窗口-边缘检测法具有较高的分类精确率, 显示该方法提取边缘的可靠性.

然而在进行迭代椭圆拟合的过程中, 除非边缘点被排除之外, 也有一部分边缘点被误排除. 这种情况发生的原因是, 在迭代的初期, 存在的非边缘点可能导致拟合出准确度较低的椭圆模型, 而靠近非边缘点的边缘点也会因此受到影响, 容易被错误地排除. 因此, 窗口-边缘检测法的结果中存在遗漏边缘点的情况, 后续的实验结果也证明了这一点. 从表 4 可知, 分类的召回率仅有 75.6%, 这影响了方法的综合性能,




图 3 窗口提取的例子. (a) 原图像, (b) 滤波图像, (c) X -边缘分布 $M(x)$ 结果, (d) Y -边缘分布 $M(y)$ 结果

Fig. 3 Example of window extraction. (a) The original frame, (b) the filtered frame, (c) the X -marginal distribution result $M(x)$, (d) the Y -marginal distribution result $M(y)$

导致检测的边缘完整性不足. 这种完整性的缺失可能会对后续的应用环节产生影响, 例如在利用检测出的边缘点拟合天体中心位置时, 可能导致中心偏移, 这一点在第 3 节的中心测量实验中也得到验证.

为解决这一问题, 引入卷积神经网络技术, 识别并补充传统的图像处理技术可能遗漏的边缘点. 根据图 2 中的流程, 在窗口-边缘检测法提取边缘的基础上, 使用基于 He 等^[14] 提出的 ResNet 调整后得到

的 LPC-ResNet 作为分类器, 对未被识别为边缘点的像素点进行进一步分类. 分类完成后, 被预测为边缘点的像素点将被补充到已有的边缘检测结果中, 从而形成更完整的边缘.

1.4 分类器

1.4.1 数据集预处理

在 1.1 节中, 经过 Canny 算子预处理和数据集标记步骤后, 这里记录了数据集中边缘点与非边缘点的




图4 窗口-边缘检测法的结果. (a) 滤波图像的窗口. (b) Y方向扫描(升序). (c) Y方向扫描(降序).

(d) X方向扫描(降序). (e) X方向扫描(升序). (f) 椭圆拟合后的结果

Fig. 4 Results of the window-contour detection method. (a) Window of the filtered frame.

(b) Scanning in Y direction (ascending order). (c) Scanning in Y direction (descending order). (d) Scanning in X direction (descending order). (e) Scanning in X direction (ascending order). (f) Results after ellipse fitting

坐标值. 由于边缘提取是像素级别的分类任务, 以这些边缘点与非边缘点的坐标值为中心, 提取该点的像素邻域图像作为训练样本, 而不直接使用完整的原始图像. 图5给出了像素邻域图像采集的结果, 使用 7×7 大小的邻域作为示例. 图1(b)中使用红色标记的像素点邻域数据作为训练的正样本, 而蓝色标记的像素点邻域数据则作为训练的负样本. 在图2所示LPC-ResNet分类器阶段, 同样采用此方式, 即对Canny算子检测出的灰度突变处像素提取邻域数据, 再输入训练完成的模型中进行类别预测.

在184幅图像中, 按照7:3的比例, 将147幅图像用于训练样本的像素邻域图像提取, 37幅图像用于测试样本的像素邻域图像提取. 基于147幅图像提取了约24万幅像素邻域图像作为训练样本, 但负样本数量占比约为77%, 而这种不平衡会影响模型的可靠性. 因此, 需要使用图像数据增强^[17]方法如旋转和翻转, 来增加像素邻域正样本数量, 如图5所示. 完成增强后, 共有近51万幅像素邻域图像用于训练, 其中约60%为正样本, 其余为负样本.

在一幅图像提取大量的像素邻域样本时, 可能会遇到冗余样本的问题. 将像素的灰度值范围分为多个区间, 且区间数量为 p ($2 \leq p \leq 256$), 即 $[0, 256/p)$, $[256/p, 2 \times 256/p)$, $\dots$, $[(p-1) \times 256/p, 256]$, 相当于 p 种精度. 若两个像素邻域样本中, 相同位置的像素灰度值落在同一个区间内, 则可以认为该位置的像素是冗余的. 如果两个样本中的所有像素都是冗余的, 则这两个样本就被认为是冗余样本. 假设像素邻域样本的边长为 n , 那么任意提取的两个像素邻域样本为冗余样本的概率为

$$P = \frac{p^{n^2}}{p^{n^2} \times p^{n^2}} = \left(\frac{1}{p}\right)^{n^2}. \quad (5)$$

以区间数量 $p=4$, 邻域边长 $n=3$ 为例, 计算可知冗余的概率为 $P = (1/p)^{n^2} = (1/4)^9 = 1/262144$. 如果在式(5)中固定 p 或 n 变量, 则另一个变量越大, 冗余的概率就越小. 因此, 随着像素邻域的扩大或灰度值区间划分得更精细, 冗余概率会呈现下降趋势. 从计算结果来看, 提取邻域样本所造成冗余的程度非常有限, 基本不会对模型训练过程造成负面影响.




图 5 像素邻域数据的训练样本采集结果, 以 7×7 大小邻域为例. 右上 5 幅子图为像素邻域数据经过数据增强后的结果, 包括 90° , 180° , 270° 旋转以及水平与垂直翻转

Fig. 5 Results of training sample collection for pixel neighborhood data, taking a 7×7 neighborhood size as an example. The five subplots in the upper right corner represent the results of data augmentation on pixel neighborhood data, including 90° , 180° , and 270° rotations, as well as horizontal and vertical flips

1.4.2 训练 LPC-ResNet

ResNet 是一种深度卷积神经网络^[14], 能对输入的图像进行分类. ResNet 的设计使得其能够有效解决深度卷积神经网络的退化问题, 因此有利于模型学习到更深层次的边缘像素点的特征. 其核心是内部的残差块结构, 如图 6 所示. 若当前输入残差块的值为 x , 则期望底层映射为 $H(x) = F(x) + x$, 最终特征学习问题转为学习残差特征, 即 $F(x) = H(x) - x$.

具体而言, ResNet 的残差块能带来更好的特征学习性能, 是因为梯度在传播的过程当中不会消失. 使用数学模型表示上述残差块结构, 设 x_l 和 x_{l+1} 分别为第 l 个残差块的输入和输出, F 为学习到的残差特征, f 为 ReLU 函数映射, $h(x_l)$ 表示对 x_l 的恒等变换映射, 则可以得到以下结果^[18]:

$$y_l = h(x_l) + F(x_l, W_l), \quad (6)$$

$$x_{l+1} = f(y_l). \quad (7)$$

进一步, 设 x_L 为浅层 l 到深层 L 的学习特征, 可求得




图 6 残差块结构

Fig. 6 Residual block structure

$$x_L = x_l + \sum_{i=1}^{L-1} F(x_i, W_i). \quad (8)$$

据此, 设损失函数的值为 S , 可求得网络反向传播过程的梯度为

$$\frac{\partial S}{\partial x_l} = \frac{\partial S}{\partial x_L} \cdot \frac{\partial x_L}{\partial x_l} = \frac{\partial S}{\partial x_L} \cdot \left[1 + \frac{\partial}{\partial x_L} \sum_{i=1}^{L-1} F(x_i, W_i) \right]. \quad (9)$$

可见, 式 (9) 中有 1 的存在, 使得梯度不会消失, 因此残差块能够在输入特征的基础之上, 学习到新的特征, 具备更好的学习性能^[18].

ResNet 并不能被直接应用于本文的研究内容中. 因此, 基于 ResNet 进行了调整, 调整后的网络结构称为 LPC-ResNet. 其不仅能够进行像素级的分类, 还能适应小规模的天王星和冥卫一的面元天体数据集. 调整分为以下两个方面.

(1) 输入层和输出层的维度. 由于是进行像素级的分类, 输入的样本不是完整的原始图像, 而是在 1.4.1 小节中的数据预处理步骤中所提取的像素邻域图像, 如图 5 所示. 对所有原图的面元天体的直径进行统计, 可以发现最小的面元直径为 10 个像素. 因此, 在提取像素邻域图像时, 仅考虑 3×3 , 5×5 , 7×7 , 9×9 这 4 种尺寸作为 LPC-ResNet 输入样本的维度, 以确保不超出整个观测对象的边界. 同时输出层维度设为 2, 对应二类分类问题.

(2) 每一层的卷积核的数量. He 等^[14] 提出了 ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 共 5 个不同的结构. 鉴于像素邻域尺寸较小且计算资源有限, 同时也为了提升预测的速度, 本

文对这 5 个结构的 conv1 层至 conv5_x 层均作卷积核数量的削减调整. 调整后的模型更加轻量化, 例如对 ResNet-18 结构进行调整后, 可训练的参数数量减少 74.9%.

表 1 中列出了经过卷积核数量调整后得到的 LPC-ResNet-18, LPC-ResNet-34, LPC-ResNet-50, LPC-ResNet-101, LPC-ResNet-152 模型的架构.

全连接层采用 softmax 函数作为激活函数, 输出归一化后的概率值, 即

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}. \quad (10)$$

由于提取边缘的过程等同于输入像素邻域数据后再将像素分类为边缘点 (类别 1) 与非边缘点 (类别 0) 的过程, 因此在计算训练损失值时, 本文采用如下通用的二元交叉熵损失函数:

$$S = -\frac{1}{N} [y_i \lg(p_i) + (1 - y_i) \lg(1 - p_i)]. \quad (11)$$

其中, N 表示训练样本的个数, y_i 表示样本 i 真实标签值 (类型 1 或类型 0), p_i 表示样本 i 预测值. 最终, LPC-ResNet 模型的训练流程如图 7 所示, 图 7 中 Canny 滤波的结果已进行了反色处理.

在后续实验中, 经统计可知, 训练后的 LPC-ResNet-18, LPC-ResNet-34, LPC-ResNet-50, LPC-ResNet-101, LPC-ResNet-152 对每幅图像的平均边缘检测耗时分别为 0.055, 0.056, 0.051, 0.088, 0.158 s, 而 Zhang 等^[12] 提出的深度神经网络对每幅

图像的平均边缘检测耗时为 4.201 s. 因此, LPC-ResNet 在预测效率上相对于 Zhang 等提出的模型有显著提升.

2 实验结果与分析

2.1 评价指标

研究中将边缘提取问题等价于二类分类问题, 因此使用精确率 (Precision, 定义符号 P)、召回率 (Recall, 定义符号 R) 以及 F_1 分数作为评价指标^[19]. 三个指标的计算公式如下:

$$P = N_{TP} / (N_{TP} + N_{FP}), \quad (12)$$

$$R = N_{TP} / (N_{TP} + N_{FN}), \quad (13)$$

$$F_1 = 2PR / (P + R). \quad (14)$$

为计算以上三个指标的值, 需要分别统计出 TP (True Positive), FP (False Positive), FN (False Negative) 的个数. TP 代表被正确分类的边缘像素点的数量, 定义符号 N_{TP} ; FP 代表被错误分类为非边缘像素点的边缘像素点, 定义符号 N_{FP} ; FN 代表被错误分类为边缘像素点的非边缘像素点, 定义符号 N_{FN} . 因此, 精确率代表了分类器能够正确识别边缘像素点的能力, 召回率代表了分类器能够找到的边缘像素点的比例, 而 F_1 分数则是前两者的综合指标. 目前, F_1 分数在图像分类以及图像分割等研究中有着广泛的应用^[20-22].

表 1 LPC-ResNet 的架构
Table 1 Architectures for LPC-ResNet

Layer_name	LPC-ResNet-18	LPC-ResNet-34	LPC-ResNet-50	LPC-ResNet-101	LPC-ResNet-152
conv1	3×3, 32	3×3, 16	3×3, 8	3×3, 8	3×3, 8
conv2_x	3×3 max pool				
	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 16 \\ 3 \times 3, 16 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 8 \\ 3 \times 3, 8 \\ 3 \times 3, 32 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 8 \\ 3 \times 3, 8 \\ 3 \times 3, 32 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 8 \\ 3 \times 3, 8 \\ 3 \times 3, 32 \end{bmatrix} \times 3$
conv3_x	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 16 \\ 3 \times 3, 16 \\ 3 \times 3, 64 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 16 \\ 3 \times 3, 16 \\ 3 \times 3, 64 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 16 \\ 3 \times 3, 16 \\ 3 \times 3, 64 \end{bmatrix} \times 8$
conv4_x	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 32 \\ 3 \times 3, 32 \\ 3 \times 3, 128 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 32 \\ 3 \times 3, 32 \\ 3 \times 3, 128 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 32 \\ 3 \times 3, 32 \\ 3 \times 3, 128 \end{bmatrix} \times 36$
conv5_x	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 3 \times 3, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 3 \times 3, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 3 \times 3, 256 \end{bmatrix} \times 3$
Output	average pool, 2d-fc, softmax				

2.2 消融实验

为研究不同像素邻域大小对 LPC-ResNet 分类性能的影响, 并且验证在二阶段算法中窗口-边缘检测法与 LPC-ResNet 两个组件的有效性, 本文均进行了相应的消融实验, 具体实验内容如下.

(1) 针对不同像素邻域大小对 LPC-ResNet 分类性能的影响, 对单独的 LPC-ResNet 分类器进行了基于像素邻域尺寸的消融实验, 也对完整的二阶段算法进行了相同的实验. 结果分别见表 2 和表 3.

(2) 针对窗口-边缘检测法与 LPC-ResNet 两个组件的有效性, 除了将表 2 与表 3 最后一列的平均值数据分别作为 LPC-ResNet 与二阶段算法的指标结果外, 还执行了单独的窗口-边缘检测法并计算出相应的指标结果. 以上指标结果均列于表 4.

2.3 与其他数字图像处理和机器学习方法的对比

为更全面评估所提出方法的性能, 加入其他数字图像处理方法与机器学习方法进行对比. 在数字图像处理方面, 使用了三个传统边缘检测算子, 即 Roberts 算子、Sobel 算子以及 Prewitt 算子对冥王星和冥卫一的面元图像进行了边缘提取^[23]. 在机器学习方面, 本文使用 Zhang 等^[12]提出的深度神经网络模型进行边缘提取, 先通过人工设计以像素点为单位的特征向量, 再将特征向量输入到网络中进行训练. 训练后的模型能对每个像素点进行分类, 并保留属于边缘点的像素点.

为了使对比更为直观, 以及进行后续的定性分析, 这里给出不同方法对冥王星和冥卫一的边缘提取结果的二值图像, 如图 8 所示. 为使被检测出的边缘清晰度更高, 对提取结果进行反色处理. 此外, 由于三




图 7 模型训练与测试流程

Fig. 7 Flow chart of model training and testing

表 2 不同结构与像素邻域尺寸条件下的 LPC-ResNet 测试结果 (准确率/召回率/ F_1 分数)
Table 2 Test results of LPC-ResNet under different numbers of layers and different pixel neighborhood sizes (Precision/Recall/ F_1 Score)

结构	像素邻域尺寸				平均值
	3×3	5×5	7×7	9×9	
LPC-ResNet-18	0.926/0.966/0.946	0.931/0.944/0.937	0.852/0.983/0.913	0.903/0.968/0.934	0.903/0.965/0.933
LPC-ResNet-34	0.936/0.920/0.928	0.901/0.980/0.939	0.919/0.957/0.937	0.854/0.979/0.912	0.903/0.959/0.929
LPC-ResNet-50	0.918/0.922/0.920	0.859/0.949/0.901	0.926/0.892/0.909	0.896/0.973/0.933	0.900/0.934/0.916
LPC-ResNet-101	0.876/0.947/0.910	0.881/0.882/0.881	0.923/0.847/0.883	0.859/0.934/0.895	0.885/0.903/0.892
LPC-ResNet-152	0.925/0.918/0.922	0.885/0.978/0.929	0.814/0.986/0.892	0.865/0.965/0.912	0.872/0.962/0.914
平均值	0.916/0.935/0.925	0.891/0.947/0.917	0.887/0.933/0.907	0.875/0.964/0.917	—

表 3 不同结构与像素邻域尺寸条件下的二阶段检测方法的测试结果 (准确率/召回率/ F_1 分数)Table 3 Test results of two-stage detection method under different numbers of layers and different pixel neighborhood sizes (Precision/Recall/ F_1 Score)

结构	像素邻域尺寸				
	3×3	5×5	7×7	9×9	平均值
窗口-边缘检测+LPC-ResNet-18	0.941/0.945/0.943	0.910/0.982/0.944	0.893/0.970/0.930	0.920/0.954/0.936	0.916/0.963/0.938
窗口-边缘检测+LPC-ResNet-34	0.936/0.939/0.937	0.873/0.982/0.925	0.906/0.950/0.927	0.919/0.973/0.945	0.909/0.961/0.934
窗口-边缘检测+LPC-ResNet-50	0.912/0.962/0.937	0.881/0.960/0.919	0.899/0.978/0.937	0.855/0.969/0.908	0.887/0.967/0.925
窗口-边缘检测+LPC-ResNet-101	0.904/0.936/0.920	0.881/0.963/0.920	0.905/0.960/0.932	0.890/0.966/0.926	0.895/0.956/0.925
窗口-边缘检测+LPC-ResNet-152	0.901/0.968/0.933	0.855/0.993/0.919	0.899/0.955/0.926	0.923/0.939/0.931	0.895/0.964/0.927
平均值	0.919/0.950/0.934	0.880/0.976/0.925	0.900/0.963/0.930	0.901/0.960/0.929	—

表 4 不同方法的精确率、召回率和 F_1 分数的结果对比Table 4 Comparison of Precision, Recall, and F_1 Score results using different methods

边缘检测方法	精确率	召回率	F_1 分数
窗口-边缘检测法	0.954	0.756	0.843
LPC-ResNet-18	0.903	0.965	0.933
LPC-ResNet-34	0.903	0.959	0.929
LPC-ResNet-50	0.900	0.934	0.916
LPC-ResNet-101	0.885	0.903	0.892
LPC-ResNet-152	0.872	0.962	0.914
窗口-边缘检测法+LPC-ResNet-18	0.916	0.963	0.938
窗口-边缘检测法+LPC-ResNet-34	0.909	0.961	0.934
窗口-边缘检测法+LPC-ResNet-50	0.887	0.967	0.925
窗口-边缘检测法+LPC-ResNet-101	0.895	0.956	0.925
窗口-边缘检测法+LPC-ResNet-152	0.895	0.964	0.927
Zhang等提出的方法	0.771	0.746	0.758
Roberts 算子	0.827	0.572	0.676
Sobel 算子	0.829	0.644	0.725
Prewitt 算子	0.829	0.643	0.724

种传统边缘算子的效果接近, 此处仅展示效果最佳的 Sobel 算子的检测结果作为示例。

边缘算子与 Zhang 等提出的方法的精确率、召回率与 F_1 分数评价指标的结果也在表 4 中给出, 以进行后续定量分析。

2.4 实验结果

2.4.1 定性分析

由图 8 可知, 窗口-边缘检测法去除非边缘点的

效果明显, 但提取边缘的完整性仍有待提高。LPC-ResNet 所提取的边缘完整性高, 但是对内部非边缘点的去除效果不佳。在两者结合后的二阶段检测方法的结果中, 提取边缘的完整性与 LPC-ResNet 接近, 引入的误判结果比 LPC-ResNet 更少。Sobel 算子仅提取少部分的边缘, 且误判的结果比二阶段检测方法更多。Zhang 等提出的方法补充了部分边缘点, 但是误判的结果最多。由此可知, 二阶段检测方法相比 So-




图 8 使用不同方法检测的冥王星边缘结果. (a) 原图像, (b) 窗口-边缘检测法的结果, (c) LPC-ResNet 检测结果, (d) 窗口-边缘检测法+LPC-ResNet 检测结果, (e) Sobel 算子结果, (f) Zhang 等提出的方法结果

Fig. 8 Contours of Pluto detected using different methods. (a) Original image, (b) the result of window-contour detection method, (c) the result of LPC-ResNet detection, (d) the result of window-contour detection method + LPC-ResNet detection, (e) the result of Sobel operator, (f) the result of method proposed by Zhang *et al.*

bel 算子, Zhang 等提出的方法与单独的 LPC-ResNet 能去除更多的非边缘点, 同时相比单独的窗口-边缘检测法能识别出更多的边缘点, 提取出更完整的边缘.

2.4.2 定量分析

由表 2 和表 3 中的数据可知, 在 3×3 的像素邻域尺寸下, 单独的 LPC-ResNet 和二阶段检测方法的综合分类性能均为最佳. 此外, 在不同的 LPC-ResNet 结构中, LPC-ResNet-18 的综合表现最佳. 结合本文所使用的样本以及 LPC-ResNet 的结构进行分析, 可知样本尺寸较小 (大小仅为 $3 \times 3 \sim 9 \times 9$), 且分类的复杂度较低 (为二类分类). 因此, 相对简单的网络结构更适合实际需求, 而消融实验的结果证明了这一点.

由表 4 可知, 单独的窗口-边缘检测法的精确率最高, 再次验证了该方法去除非边缘点的能力最强. 而在加入 5 种不同结构的 LPC-ResNet 作为分类器后, 分类的召回率与 F_1 分数相比窗口-边缘检测法均有明显提升, 其中召回率的提升最高可达 20.9%. 同

时, 二阶段检测方法也比单独的 LPC-ResNet 分类器取得更好的 F_1 分数, 综合性能更好. 因此, 消融实验证实了两个组件在二阶段检测方法中的有效性, 两者同时存在时能达到最佳的分类性能.

基于实验结果, 并结合窗口-边缘检测法与 LPC-ResNet 网络结构的原理, 对窗口-边缘检测法的优势和局限性以及 LPC-ResNet 的作用进行了分析, 得到结果如下.

(1) 窗口-边缘检测法精确率较高, 而召回率较低. 这是因为该方法从外到里搜索边缘点, 能尽可能去除 Canny 算子检测的内部灰度突变处像素, 减少了被误分类为边缘点的非边缘点, 提高了精确率. 召回率较低的原因可能是因为部分边缘点在迭代椭圆拟合过程中被误排除, 具体细节已在 1.4 节进行说明.

(2) 在引入 LPC-ResNet 作为分类器并执行二阶段的边缘检测流程后, 召回率有明显的提升. 然而, 精确率并没有得到改善, 这是因为数据集规模有限和计算资源不足, 尚未充分发挥 LPC-ResNet 的最佳性能, 因此在单独的窗口-边缘检测法基础之上引入少

量误判结果. 但是作为基于 ResNet 的深度卷积神经网络, LPC-ResNet 充分学习了像素边缘点的邻域特征, 使得二阶段检测方法相对于窗口-边缘检测法和 Zhang 等^[12]提出的方法, 展现出在构建深层网络以及自动提取特征方面的优势, 因此能够保留更多的边缘点, 从而提升了召回率.

3 中心测量应用实验

在边缘提取实验中, 本文提出的面向小规模面元天体数据集的边缘检测方法, 以及单独的窗口-边缘检测法分别取得了最高的召回率和精确率. 为进一步验证 LPC-ResNet 网络作为分类器在改善边缘检测效果上的作用, 基于二阶段检测方法与单独的窗口-边缘检测法的边缘提取结果, 进行了冥王星和冥卫一的中心测量应用实验.

3.1 实验流程

中心测量实验的具体步骤如下.

步骤 1 对两种方法检测到的边缘点, 应用式 (3) 和式 (4) 中的椭圆方程和目标函数, 计算天体在图像中的中心坐标, 即观测中心 (x_o, y_o) . 根据前面边缘检测所取得的实验结果, 使用的 LPC-ResNet 结构均为 LPC-ResNet-18, 提取的像素邻域大小均设置为 3×3 , 以取得最好的测量效果.

步骤 2 从 Plu060 历表中提取天体的赤经赤纬坐标 (α_c, δ_c) , 并利用 Owen 提出的相机模型, 将 (α_c, δ_c) 转化为理论中心 (x_c, y_c) . 该相机模型在天体测量研究中曾被多次使用^[24,25]. Plu060 历表的数据, 可以从美国国家航空航天局 (NASA) 的归档数据中获取^[26].

步骤 3 利用观测中心 (x_o, y_o) 与理论中心 (x_c, y_c) , 计算出 (O-C) 像素误差值, 即观测中心与理论中心之间的差值 $(x_o - x_c)$ 与 $(y_o - y_c)$.

步骤 4 考虑到数据集中图像分辨率的变化范围较大 ($2.31 \sim 148.69 \text{ km-pixel}^{-1}$), 使得像素误差难以准确反映实际测量精度, 本文利用了 (O-C) 像素误差与图像分辨率相乘计算出归一化后的误差, 即 (O-C) 公里误差.

完成实验后, 对 (O-C) 公里误差进行统计, 计算出均值和标准差 (见表 5).

3.2 实验结果分析

由表 5 可知, 当 LPC-ResNet 与窗口-边缘检测法结合后, 在 x 方向和 y 方向上的 (O-C) 公里误差的均值与标准差均比单独的窗口-边缘检测法更低, 表明其测量精度得到提升, 特别是在 x 方向上的改善更为显著. 这表明二阶段检测方法所检测到的边缘点在进行椭圆拟合的过程中表现更佳, 进而提高了中心测量的精度. 因此, 该结果证明了在提取冥王星和冥卫一图像的边缘时, LPC-ResNet 作为分类器部分, 对于改善边缘检测效果是有意义的.

4 结论

提出一种面向小规模的面元天体数据集的二阶段边缘检测方法, 该方法由窗口-边缘检测法与 LPC-ResNet 分类器组成. 其中窗口-边缘检测法是基于数字图像处理技术的方法, 用于初步提取边缘; 而 LPC-ResNet 是基于 He 等^[14]提出的 ResNet 所调整得到的像素级边缘分类器, 用于补充可能被窗口-边缘检测法遗漏的边缘点. 为更全面评估所提出方法的性能, 使用边缘检测算子以及 Zhang 等^[12]提出的神经网络模型进行了对比. 最后, 为验证 LPC-ResNet 分类器对边缘提取结果的改善作用, 还进行了对冥王星与冥卫一的中心测量应用实验.

边缘提取实验的结果表明, 无论是单独的窗口-边缘检测法, 单独的 LPC-ResNet 分类器还是二阶

表 5 窗口-边缘检测法与二阶段检测方法在 x 和 y 方向的 (O-C) 误差均值与标准差 (以 Plu060 历表为参考)
Table 5 Mean and standard deviation of (O-C) errors in x and y directions of the window-contour detection method and the two-stage detection method, using the Plu060 ephemeris as reference

测量指标	窗口-边缘检测法	窗口-边缘检测法+LPC-ResNet
x 方向(O-C)误差均值/km	-25.13	-11.52
x 方向(O-C)误差标准差/km	74.86	66.56
y 方向(O-C)误差均值/km	-16.55	-10.81
y 方向(O-C)误差标准差/km	39.27	38.00

段检测方法, 在边缘检测效果上均优于传统算子以及 Zhang 等^[12] 提出的神经网络模型. 窗口-边缘检测法去除非边缘点的性能最佳, 取得了最高的精确率; 而引入 LPC-ResNet 的二阶段检测方法则补充了被窗口-边缘检测法所遗漏的部分边缘点, 相比单独的窗口-边缘检测法和单独的 LPC-ResNet 分类器效果均更佳. 同时, 中心测量实验也表明 LPC-ResNet 能够有效改善测量的精度, 显示出在应用层面的意义.

总体来说, 在面向小规模的面元天体数据集的二阶段边缘检测方法中, 窗口-边缘检测法的阶段没有深度学习过程, 且 LPC-ResNet 分类器也较为轻量级. 因此, 该方法可以应用于小规模的天体面元数据集. 例如, 在 PDS Image Atlas 中的新视野号远程勘测成像仪图像集, 也包含了部分木星卫星图像, 但是数量相当有限. 此外, 该方法还可以根据实际情况灵活使用. 在长期探测任务的早期阶段中, 数据集的规模一般很小, 这使得 LPC-ResNet 分类器的识别效果不佳. 因此, 可以先使用二阶段检测方法的第一阶段即窗口-边缘检测法提取初步边缘, 并在后续数据集规模扩大后, 再加入 LPC-ResNet 来进一步提升边缘提取的完整性.

未来还可以进一步利用 SPICE 辅助数据库^[26] 中的 PCK 文件来优化窗口-边缘检测法的结果, 以及通过扩大数据集规模和优化模型架构来提升 LPC-ResNet 的分类性能.

参考文献

- [1] COOPER N J, LAINEY V, MEUNIER L E, *et al.* The Caviar software package for the astrometric reduction of Cassini ISS images: description and examples[J]. *Astronomy & Astrophysics*, 2018, **610**: A2
- [2] ZHANG Q F, LAINEY V, COOPER N J, *et al.* First astrometric reduction of Cassini Imaging Science Subsystem images using an automatic procedure: application to Enceladus images 2013-2017[J]. *Monthly Notices of the Royal Astronomical Society*, 2018, **481**(1): 98-104
- [3] ZHANG Q F, QIN W H, MA Y L, *et al.* Complementary astrometry of Cassini Imaging Science Subsystem images of phoebe[J]. *Planetary and Space Science*, 2022, **221**: 105553
- [4] WANG Zhiqiang, LIU Mengqi, ZHANG Qingfeng, *et al.* Astrometry of Cassini ISS images of 7 near-ring inner satellites of Saturn affected by scattered light[J]. *Acta Astronomica Sinica*, 2023, **64**(6): 69 (王志强, 刘梦琪, 张庆丰, 等. Cassini 图像中受散射光影响的 7 颗土星近环内卫星的天体测量 [J]. 天文学报, 2023, **64**(6): 69)
- [5] PORTER S B, CANUP R M. Orbits and masses of the small satellites of Pluto[J]. *The Planetary Science Journal*, 2023, **4**(7): 120
- [6] WANG L L, YU Y, YULDOSHEV Q X, *et al.* New reduction of old glass astronomical plates of Pallas and Vesta in 1956-1994 based on Gaia DR3 catalogue[J]. *Planetary and Space Science*, 2023, **227**: 105637
- [7] NIMMO F, UMURHAN O, LISSE C M, *et al.* Mean radius and shape of Pluto and Charon from New Horizons images[J]. *Icarus*, 2017, **287**: 12-29
- [8] GUO Y P, FARQUHAR R W. New Horizons mission design[J]. *Space Science Reviews*, 2008, **140**(1): 49-74
- [9] STERN S A, BAGENAL F, ENNICO K, *et al.* The Pluto system: initial results from its exploration by New Horizons[J]. *Science*, 2015, **350**(6258): aad1815
- [10] ZHARKOVA V V, IPSON S S, ZHARKOV S I, *et al.* A full-disk image standardisation of the synoptic solar observations at the Meudon Observatory[J]. *Solar physics*, 2003, **214**(1): 89-105
- [11] YUAN Fei. Research on the Real-time Monitoring and Forecasting Method of Solar Flare[D]. Beijing: University of Chinese Academy of Sciences, 2017 (袁飞. 太阳耀斑实时监测与预报方法的研究 [D]. 北京: 中国科学院大学, 2017)
- [12] ZHANG Qingfeng, ZHENG Yang, CHENG Guohao, *et al.* Contour detection of disk resolved objects in Cassini ISS Image using deep neural network[J]. *Chinese Journal of Space Science*, 2020, **40**(2): 289-295 (张庆丰, 郑洋, 成国豪, 等. 使用深度神经网络检测 Cassini ISS 图像中圆盘状星体轮廓 [J]. 空间科学学报, 2020, **40**(2): 289-295)
- [13] YANG X Q, ZHANG Q F, LI Z. Contour detection in Cassini ISS images based on Hierarchical Extreme Learning Machine and Dense Conditional Random Field[J]. *Research in Astronomy and Astrophysics*, 2020, **20**(1): 011
- [14] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778
- [15] WEAVER H A, CHENG A F, MORGAN F, *et al.* In-flight performance and calibration of the Long Range Reconnaissance Imager (LORRI) for the New Horizons mission[J]. *Publications of the Astronomical Society of the Pacific*, 2020, **132**(1009): 035003
- [16] PUKELSHEIM F. The three sigma rule[J]. *The American Statistician*, 1994, **48**(2): 88-91
- [17] XU M L, YOON S, FUENTES A, *et al.* A comprehensive survey of image augmentation techniques for deep learning[J]. *Pattern Recognition*, 2023, **137**: 109347
- [18] ZHANG Wei, ZHANG Mi, JIN Jiaqi, *et al.* Research on status identification of disconnecter based on ResNet deep learning network[J]. *High Voltage Apparatus*, 2024, **60**(6): 99-106 (张伟, 张咪, 金佳齐, 等. 基于 ResNet 深度神经网络的隔离开关状态识别研究 [J]. 高压电器, 2024, **60**(6): 99-106)
- [19] OPITZ J, BURST S. Macro F1 and macro F1[OL]. arXiv

- preprint arXiv: 1911.03347, 2019
- [20] CHEN S, GAMECHI Z S, DUBOST F, *et al.* An end-to-end approach to segmentation in medical images with CNN and posterior-CRF[J]. *Medical Image Analysis*, 2022, **76**: 102311
- [21] YU Q, SHI C. An image classification approach for painting using improved convolutional neural algorithm[J]. *Soft Computing*, 2024, **28**(1): 847-873
- [22] AL-ZEBARI A. Ensemble convolutional neural networks and transformer-based segmentation methods for achieving accurate sclera segmentation in eye images[J]. *Signal, Image and Video Processing*, 2024, **18**(2): 1879-1891
- [23] FENG Wei, LIU Guangyu, CAO Yu, *et al.* A comparative study of image edge detection with typical differential operators[J]. *Journal of Henan Institute of Science and Technology (Natural Science Edition)*, 2022, **50**(4): 54-61 (冯伟, 刘光宇, 曹禹, 等. 典型微分算子的图像边缘检测对比研究 [J]. 河南科技学院学报 (自然科学版), 2022, **50**(4): 54-61)
- [24] COOPER N J, MURRAY C D, PORCO C C, *et al.* Cassini ISS astrometric observations of the inner Jovian satellites, Amalthea and Thebe[J]. *Icarus*, 2006, **181**(1): 223-234
- [25] COOPER N J, MURRAY C D, LAINEY V, *et al.* Cassini ISS mutual event astrometry of the mid-sized Saturnian Satellites 2005-2012[J]. *Astronomy and Astrophysics*, 2014, **572**: A43
- [26] ACTON JR C H. Ancillary data services of NASA's Navigation and Ancillary Information Facility[J]. *Planetary and Space Science*, 1996, **44**(1): 65-70

作者简介



郑 洋 男, 1996 年 7 月出生于广东省茂名市, 现为广东海洋大学数学与计算机学院助教, 主要研究方向为空间天体测量技术、计算机视觉。

E-mail: wlwzy@gdou.edu.cn



郑中杰(通信作者) 男, 1988 年 1 月出生于广东省茂名市, 现为广东海洋大学数学与计算机学院讲师, 主要研究方向为图像处理、高精度天体测量。

E-mail: azhengzj@gdou.edu.cn