

冲击实验中复杂流场的准静止区检测

徐悦, 曾强, 李然, 陈泉, 李一鸣, 牟彤彤, 杨晖

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 颗粒流场特征检测通常采用粒子图像测速(PIV)技术测得速度场, 再对多帧连续图像进行人工识别, 检测结果存在一定的主观误差。因此, 提出了一种在单帧流场图像中识别准静止区的DC-UNet++网络。首先, 通过电荷耦合器件(CCD)采集小球冲击颗粒床形成的流场图像, 再用PIV技术分析并制作数据集。然后, 在多组数据集上训练CNN模型、UNet++模型和提出的DC-UNet++模型, 验证分析其在单帧图像上检测准静止区的可行性与准确性。最后, 讨论了该模型在非透明和透明两类颗粒材料中的低速冲击流场上的泛化能力。实验结果表明: DC-UNet++网络在非透明和透明颗粒材料上的准确率分别达到87.76%和72.91%。DC-UNet++网络实现了在单帧图像上检测目标特征的任务, 且对透明颗粒材料复杂流场下的特征仍具有较为准确的检测结果。

关键词: 光学测量; PIV速度场; 图像处理; 扩张卷积; 特征检测

中图分类号: TP 394.1; O 313.4

文献标志码: A

Quasi-static region detection of complex flow field in the impact experiments

XU Yue, ZENG Qiang, LI Ran, CHEN Quan, LI Yiming, MU Tongtong, YANG Hui

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Current feature detection in particle flow fields was commonly measured by the particle image velocimetry (PIV) followed by manual identification of multiple consecutive frames, which is subject to some subjective errors. Therefore, a DC-UNet++ network for identifying the quasi-static regions in single-frame flow field images was proposed. Firstly, the particle flow field images formed by the impact experiments between the small ball and particle bed were captured by a high-speed charge coupled device (CCD) camera. Next, the raw images were used for PIV analysis and a dataset was produced. Then, the CNN model, UNet++ model and the proposed DC-UNet++ model were trained on multiple datasets to validate and analyze their feasibility and accuracy in detecting the quasi-static regions on a single frame image. Finally, the ability of the model to generalize over low velocity impact flow fields in non-transparent and transparent granular materials was discussed. The experimental

收稿日期: 2022-11-09

基金项目: 国家自然科学基金资助项目(12072200, 12002213); 青岛海洋科学与技术国家实验室鳌山科技创新计划项目(2021QNLM020002-7); 上海市自然科学基金资助项目(20ZR1438800)

第一作者: 徐悦(1997-), 男, 硕士研究生。研究方向: 颗粒技术。E-mail: 202330358@st.usst.edu.cn

通信作者: 杨晖(1981-), 男, 教授。研究方向: 颗粒技术。E-mail: yanghui@usst.edu.cn

results showed that the DC-UNet++ network achieved an accuracy of 87.76% and 72.91% on non-transparent and transparent granular materials, respectively. The DC-UNet++ network achieved the task of detecting the target features on a single image frame and still had a relatively accurate detection of features under complex flow fields in transparent granular materials.

Keywords: optical measurement; PIV velocity field; image processing; dilated convolution; feature detection

从伽利略观察到月球表面粗糙，到隼鸟号探测器撞击龙宫小行星^[1]，研究人员采用先进观测技术，不断深入了解陨石坑的结构和形成过程。陨石撞击形成陨石坑、探测器着陆^[1]和导弹发射/摧毁目标^[2]等冲击过程，均会产生复杂的颗粒流场，比如，冲击坑内的物质飞溅(外侧)区域、崩塌(内侧)区域都会随着流场的演化而向外扩张^[3-6]。检测飞溅、崩塌和飞溅与崩塌之间的过渡区对冲击坑的演化研究具有重要价值。

颗粒测量技术不断发展，当前非接触式分析测量技术可分为数字图像法^[7]和非图像法。在颗粒流场中使用数字图像法较为普遍，主要有粒子图像测速 (particle image velocimetry, PIV) 技术、粒子追踪测速 (particle tracking velocimetry, PTV) 技术、空间滤波测速 (spatial filtering velocimetry, SFV) 技术^[8-11]和激光扫描技术。Sirasitthichoke 等^[12]利用 PIV 分析速度场进而人工识别了具有微小扰动的射流特征。Siegel 等^[13]用 PIV 分析了风洞中钝体绕流的涡旋特征，但涡旋的数量和位置仍然需要人工识别。Simon 等^[14]使用激光轮廓技术对实验中冲击坑数字化建模，进而对坑的切面进行双曲线拟合，分析了飞溅、崩塌等特征区域。颗粒流场中的特征检测普遍通过速度场进行，冲击过程变化快，检测难度大，冲击坑中的特征检测较少。因此，在复杂流场中寻求更为合适的特征检测和提取方法至关重要。

图像是像素的集合，像素值由红、绿、蓝 3 个通道组成并在空间上相关，从而表达图像中的宏观信息^[15]。颗粒流场是颗粒及其复杂运动的集合，例如，在斜槽上堆积的密集颗粒流中，崩塌被视为宏观信息^[15]。将图像的像素与颗粒流场的颗粒及其运动属性建立联系，表明可以使用神经网络算法在颗粒流场中进行特征检测。Delatte 等^[16]通过机器学习方法检测了月球图像上的陨石坑，但并未对坑内的细节特征进行研究。对于检测图

像的特征细节，U-Net^[17]和 UNet++^[18]网络应用较为普遍和高效^[19-21]。UNet++网络^[18]能够在复杂的图像分割任务中检测出目标特征，不需依赖速度场和人工识别。因此，基于该框架提出一种适用于密集颗粒流的模型，有望实现冲击过程的特征区域检测和任务提取。

本文对冲击与崩塌转变边界的检测和提取技术进行了研究，提出一种在单帧流场图像上识别其特征区域的 DC-UNet++网络。通过电荷耦合器件 (CCD) 采集球体冲击颗粒床的流场图像数据，使用卷积神经网络 (CNN) 和 DC-UNet++网络分别在速度场和流场图像上建立特征检测模型。PIV 法在进行复杂的相关分析后，仍需要人工对数据进行分析 and 处理，并设置阈值来提取场特征，而 DC-UNet++网络达成了在单帧图像上直接检测获得目标特征的任务。最后，DC-UNet++网络验证了模型在不同材料颗粒上的普适性，评估了模型识别准静止区的准确率，并将检测结果进行可视化呈现，来弥补 PIV 法只能对黑色颗粒进行速度矢量场提取的缺陷。

1 复杂流场的特征检测网络

1.1 适用于密集流场中的 DC-BN 块

图 1 为 DC-BN 块结构，该结构基于扩张卷积和归一化层^[22]，用于提取复杂颗粒流场中的特征信息。图中，ReLU 为激活函数。扩张卷积是一种带有扩张滤波器的卷积^[23]，用于连接密集区域中的上下文信息^[24]。与常规卷积相比，扩张卷积在复杂流场中捕获的特征信息更广泛，特征差异表现更明显。因此，扩展卷积在连接密集区域的上下文信息方面表现出良好的性能^[24-25]。扩张卷积有一个超参数，称为扩张率 (dilation rate)，它是指卷积核中间隔的数量。普通卷积中卷积核的扩张率为 1，此处扩张卷积中卷积核的扩张率设为 2。引




图 1 DC-BN 块
Fig.1 Blocks of DC-BN

入扩张卷积仅仅是为了调节卷积核之间的间隔, 而不是为了改变卷积的数量和尺寸。因此, DC-BN 块的引入并不会增加网络结构的参数量。

1.2 DC-UNet++网络结构

Zhou 等^[18]在 2020 年提出了 UNet++网络, 通过使用一系列嵌套且密集的卷积块弥补了特征映射跳过路径之间的语义差距, 提升了图像分割的

精度。将 DC-BN 块引入 UNet++网络结构中将更加适用于密集的颗粒流场。因此, 基于 UNet++网络, 通过增加 DC-BN 块, 提出了图 2 所示的 DC-UNet++网络。

如图 2 所示, 图像数据输入至 $X^{0,0}$ 处的 DC-BN 块后, 输出的特征图通过下采样和跳跃连接进入下一个 DC-BN 块中。L1~L4 分别是经过 1 至 4 次下采样和上采样的网络结构。最终特征图通过一系列的编码和解码后从 $X^{0,4}$ 处输出。

DC-UNet++网络中, 下采样为 2×2 大小的最大池化层, 上采样为 2×2 大小的反卷积层, 特征图的拼接使用特征融合层实现。每个卷积层后都由激活函数 ReLU 负责将神经元的输入映射到输出。ReLU 函数表达式如下:

$$f(x) = \max(0, x) \tag{1}$$




图 2 DC-UNet++网络结构
Fig.2 Network structure of DC-UNet++

在模型最终输出时使用激活函数 Sigmoid 得到结果, Sigmoid 函数表达式如下:

$$S(x) = \frac{1}{1 + e^{-x}} \tag{2}$$

1.3 评价方式

在复杂流场的特征提取中, 需要检查模型获得的准静止区域的准确度。图像分割领域常使用 dice 系数^[26-27]表示特征提取结果与标签之间的相似度。因此, 使用 dice 系数作为结果准确性的评估指标。当相似度值接近 1 时, 结果和标签之间的差异很小。当相似度值接近 0 时, 结果和标签之间的差异变得明显。dice 系数计算表达式为

$$D_{\text{dice}} = \frac{2 \times (R_{\text{SEG}} \cap R_{\text{GT}})}{R_{\text{SEG}} \cup R_{\text{GT}}} \tag{3}$$

式中: D_{dice} 表示 dice 系数; R_{SEG} 表示模型提取的

特征区域; R_{GT} 表示标签中的特征区域。

2 实验数据采集及预处理

2.1 数据采集实验装置

冲击实验装置如图 3 所示, 使用磁铁控制小球自由下落, 来冲击颗粒床。球体直径为 3.0 cm, 重 17 g, 释放高度距离颗粒床面 50 cm。在实验中, 球体接触颗粒床时的冲击速度约为 3.13 m/s, 属于低速碰撞。颗粒床层厚度为 1.2 cm, 颗粒直径为 0.8~1.0 mm。颗粒由自然重力堆积, 堆积密度约为 2.46 g/cm³。实验过程用 CCD 摄像机(5F04, 586 fps)从顶部拍摄, 同时用白光源照亮颗粒床, 以采集球体撞击颗粒床的流场图像。图像采集的详细参数如表 1 所示。




图 3 球体冲击颗粒床的实验装置

Fig.3 Experimental device for the impact between the sphere and granular bed

表 1 图像采集的参数设置

Tab.1 Parameters setting of the image acquisition

相机参数	数值
曝光时间/ μ s	230~400
采集频率/fps	586
采集周期/ μ s	2000
采集窗口/px	960×960
水平分辨率/dpi	96
垂直分辨率/dpi	96

2.2 目标特征区域

实验中采集的流场图像以球体接触颗粒床为起始时刻。球体冲击颗粒床后，床层颗粒的运动和形态演化过程中，会出现一个速度为 0 的特征区域，称之为准静止区。它存在于冲击坑内侧的塌落颗粒和外侧的飞溅颗粒之间，并随着冲击坑的演化而向外扩张。准静止区域描述了冲击坑中崩塌的边缘，对它的识别有助于观测和理解崩塌的运动机制。图 4 为某一时刻准静止区域的位置，可知其有 3 个特征：a. 所处位置颗粒速度为 0；b. 其内外侧的颗粒速度方向相反；c. 具有一定的宽度。图 4(b) 则为该流场中的速度为 0 的颗粒，准静止区域位于两条黑色虚线之间，其半径为 r ，宽度为 w ，而其他蓝色颗粒是撞击坑外的静止颗粒。为了得到含有准静止区域的流场图像数据，分别在黑色球形颗粒和透明球形颗粒组成的颗粒床上进行冲击实验^[28]。

2.3 数据集构建

通过实验采集的图像数据，构建了黑色球形颗粒组成的 db_1、db_2、db_3 和透明球形颗粒组成的 dt_1 数据集。数据集 db_1、db_2 的数据格式如图 5(a) 和 (b) 所示，数据集 db_3、dt_1 的数据




图 4 某一时刻的准静止区域

Fig.4 The quasi-static region at one moment




图 5 各组数据集的格式

Fig.5 Format of the data sets

格式如图 5(c) 和 (d) 所示。首先，将图像 (960 px × 960 px) 数据进行 PIV 处理，PIV 窗口设为 8 × 8，获得 119 × 119 × 2 的矩阵格式速度场数据。该矩阵由每帧图像的速度场数据组成，矩阵元素依次为高度、宽度和通道 (包括横向速度和纵向速度)。其次，通过 image data generator (集成的模块，能够对图像进行旋转、变形和归一化，用于增加图像的样本数量) 对原始图像进行扩充，扩充方式有任意角度旋转、水平或垂直平移 (位移幅度在 10% 以内)。最后，将扩充的黑色球形颗粒和透明球形颗粒的流场图像分别构建为数据集 db_3 和

dt_1(每帧图像包含 R, G, B 3 个通道)。

数据标签的物理含义是具有准静止区域特征的区域,即该区域速度为 0,其两侧的速度方向相反。两种数据格式的标签如图 5(b)和(d)所示。4 组数据集的标签制作有以下 4 个步骤: a. 通过 PIV 对多幅原始图像进行分析,得到速度场分布图和速度数据; b. 将速度数据(包括横向速度和纵向速度)映射到直角坐标系,计算出中心点后坐标变换; c. 将速度分布从直角坐标系转换为极坐标系; d. 在极坐标系中计算每个角度的径向速度分布,然后选择准静止区域并指定标签。表 2 为实验所用数据集的详细参数。

表 2 数据集的参数及大小

Tab.2 Parameters and size of the data sets

数据集	颗粒类型	颗粒直径/mm	数据形式	数据大小
db_1	黑色玻璃珠	0.80~1.00	速度场	27
db_2	黑色玻璃珠	0.80~1.00	速度场	27
db_3	黑色玻璃珠	0.80~1.00	图像	260
dt_1	透明玻璃珠	0.85~1.18	图像	220

3 实验结果与讨论

3.1 速度场中建模

实验 1 使用的 CNN 模型如表 3 所示,含有 4 层卷积层,隐藏层中使用 ReLU 作为激活函数,最后输出选用 Sigmoid 作为激活函数。数据集使用

表 3 CNN 模型的结构参数

Tab.3 Structural parameters of the CNN model

层类型	激活函数	输出大小
输入层	—	(119,119,2)
卷积(16层,卷积核:5×5)	ReLU	(119,119,16)
卷积(64层,卷积核:5×5)	ReLU	(119,119,64)
卷积(16层,卷积核:5×5)	ReLU	(119,119,16)
卷积(1层,卷积核:5×5)	Sigmoid	(119,119,1)
输出层	—	(119,119,1)

表 2 所示的 db_1 和 db_2,训练测试比为 8 : 2(数据集的格式如图 5 所示)。

图 6 是 CNN 模型在不同数据集下的损失-准确率曲线,分别验证了在单独数据集 db_1 (图 6(a))和混合数据集(db_1 和 db_2 混合)上(图 6(b))模型的可行性与稳定性。如图 6(a)所示,训练集和测试集上的损失都随着迭代次数的增加而稳定下降,同时,准确率收敛平稳且波动较小,能保持在 88% 左右。将数据集 db_1 和 db_2 混合后再进行模型测试是非常有必要的,这有助于分析相同条件下物理实验中产生的批量数据,尤其是有助于分析流场中速度场与其特征区域的联系。如图 6(b)所示,在同一颗粒体系下产生的两组数据集 db_1 和 db_2 混合后,模型的损失-准确率曲线收敛平稳,准确率保持在 85% 以上。这表明 CNN 模型仍可以精确建模,为大尺度下复杂速度场中微弱特征的识别问题提供了有效的解决方案。




图 6 实验 1 中 CNN 模型在不同数据集上的损失-准确率曲线

Fig.6 Loss-dice curve of the CNN model on different data sets in Experiment 1

3.2 流场图像中建模

在流场图像中采用 UNet++和 DC-UNet++网络对特征区域建模。通过图像像素间接分析颗粒及

其运动特性的宏观信息,从复杂颗粒流场图像中提取特征。图像中的像素记录了在设定的曝光时间内颗粒的移动轨迹,而静态颗粒没有这样的轨

迹，只有一个点。因此，可以使用单帧图像来识别特征。

实验 2 在黑色球形颗粒形成的流场图像数据集 db_3 中对特征区域进行建模，并将 UNet++ 和被提出的 DC-UNet++ 网络进行比较。数据集 db_3 按 8 : 2 划分用于训练和测试模型。UNet++ 和 DC-UNet++ 网络的损失和准确率如图 7 (a) 和 (b) 所示。当模型的训练轮次均为 100 时，UNet++ 网络的损失有一定波动，保持在 0.13 左右，其训练准确率逐渐上升，但测试准确率稳定在 70% 左右；而提出的 DC-UNet++ 网络在损失和准确率上都具有更好的收敛性，损失保持在 0.1 以下，并且测试准确率能稳定在 80% 以上，比 UNet++ 网络的准确率高出 10%。DC-UNet++ 网络实现了在图像中直接提取复杂颗粒流场特征区域的功能。在颗粒流体系中，这一框架的应用是新颖的。实验 2 的结果表明，尽管在曝光时间较短的流场图像中，UNet++ 和 DC-UNet++ 网络仍可以对其特征区域进行建模。此外，DC-UNet++ 网络着重应用于密集颗粒流场，从而在特征提取的结果上优于 UNet++ 网络。

实验 3 在透明球形颗粒形成的流场图像数据集 dt_1 中对特征区域进行建模，将 dt_1 按 8 : 2 划分用于 DC-UNet++ 模型的训练和测试。与黑色球形颗粒相比，透明球形颗粒具有反射、折射及透射等光学特性。受上述光学特性的影响，PIV 技术在透明球形颗粒组成的流场中被认为是无效的。因此，实验 3 考察了 DC-UNet++ 在不同颗粒材料下的适用性。图 7 (c) 所示为 DC-UNet++ 在透明颗粒材料上建模的损失-准确率曲线，该模型的损失-准确率曲线仍具有波动小、收敛平稳等特点，且在 PIV 难以分析的透明颗粒材料上，该模型的训练准确率在 80% 以上，测试准确率也超过了 70%。实验 3 表明，DC-UNet++ 具有良好的鲁棒性，它能够应用于不同颗粒材料中。

3.3 准静止区识别结果

实验 1~3 通过 CNN，UNet++ 和 DC-UNet++ 建模，实现了在速度场与流场图像中识别特征区域的目标。本文对各模型得到的识别结果进行可视化，用于进一步分析颗粒流场。可视化图像采用冲击球体的直径 (D) 与颗粒床中颗粒直径 d 之比作为长度尺度。

实验 1 中两组的可视化结果如图 8 (a) 和 (b) 所




图 7 UNet++ 和 DC-UNet++ 在图像数据集中的损失-准确率曲线

Fig.7 Loss-dice curves of the UNet++ and DC-UNet++ model in image data sets

示，虽然在边缘处存在较少的错误识别和未识别区域，但仍能够准确反映特征区域的空间特征。其环形宽度为 15~20 层颗粒直径，错误识别和未识别区域在 2~4 层颗粒直径范围内。结合表 4 中实验 1 的结果，CNN 模型在两种情形下都表现出色(准确率分别为 88.69% 和 85.29%)。这是因为 CNN 建立模型时考虑了速度场的空间分布特征，而非单一地通过速度阈值进行提取。速度场分布描述了颗粒系统中每一个颗粒的运动属性，对颗粒系统中的宏观特性(如准静止区域)进行建模时，重要的是要考虑颗粒的空间相关性和相对排列。这




图 8 各模型在测试集识别结果

Fig.8 Recognition results of each model in the test sets

表 4 实验训练的模型及测试准确率

Tab.4 Experimental training model and test accuracy

实验	结构	数据集	dice系数
1	CNN	db_1 (8 : 2)	0.886 9
	CNN	db_1 和 db_2 (8 : 2)	0.852 9
2	UNet++	db_3 (8 : 2)	0.683 0
	DC-UNet++	db_3 (8 : 2)	0.877 6
3	DC-UNet++	dt_1 (8 : 2)	0.729 1

表明,神经网络算法可以在颗粒流的速度场上建立特征识别模型。

图 8(c)和(d)分别为实验 2 两种模型的可视化结果。图中可以观察到,UNet++提取的特征区域在环形宽度上表现不稳定,误差在 6~10 层颗粒直径范围内(表 4,准确率为 68.30%),而 DC-UNet++提取的特征区域在环形宽度上误差小,仅在边缘有较小的不准确区域(2~4 层颗粒直径),其准确率达到 87.76%(表 4)。此外,与 CNN 和 UNet++模型相比,其特征区域的边缘更加平滑,且没有较大的错误识别区域(图 8(d))。图 8(e)为实验 3 中特征提取的可视化结果,这一结果是准确的,误差在 3~6 层颗粒直径范围内,准确率达到 72.91%(表 4)。图中可见,在透明颗粒材料组成的流场图像上,DC-UNet++模型受到一定的影

响,主要表现在特征边缘的块状错误识别区域。这是颗粒材料的光学特性导致的,由于光在透明颗粒材料中折射和透射^[29],使得采集实验图像时出现较多的光斑,从而影响模型的识别。

4 结 论

颗粒流场的特征检测中,粒子图像测速测得速度场后,还需人工对多帧连续图像进行识别,本文提出了一种直接在单帧流场图像上检测特征的建模方法(DC-UNet++网络)。相较于 PIV 分析速度场再人工识别特征的方法,DC-UNet++网络实现了在单帧图像上检测目标特征的任务,且在两种不同颗粒材料上的识别准确率分别达到 87.76%和 72.91%。结果表明,即使在具有透射、折射性质的透明颗粒材料中,本文模型仍是适用的,这也为探索冲击流场中的图像特征检测提供了一种新的思路。

参考文献:

[1] ARAKAWA M, SAIKI T, WADA K, et al. An artificial impact on the asteroid (162173) Ryugu formed a crater in the gravity-dominated regime[J]. Science, 2020, 368(6486): 67–71.

- [2] 朱孙科, 罗天洪, 徐向阳. 导弹尾部燃气冲击射流的流场特性仿真研究[J]. 计算机仿真, 2017, 34(2): 123–127.
- [3] BOUDET J F, AMAROUCHENE Y, KELLAY H. Dynamics of impact cratering in shallow sand layers[J]. *Physical Review Letters*, 2006, 96(15): 158001.
- [4] RUIZ-SUÁREZ J C. Penetration of projectiles into granular targets[J]. *Reports on Progress in Physics*, 2013, 76(6): 066601.
- [5] VAN DER MEER D. Impact on granular beds[J]. *Annual Review of Fluid Mechanics*, 2017, 49(1): 463–484.
- [6] DEBOEUF S, GONDRET P, RABAUD M. Dynamics of grain ejection by sphere impact on a granular bed[J]. *Physical Review E*, 2009, 79(4): 041306.
- [7] 黄凌霄, 廖一鹏. 浮选气泡 NSCT 域多尺度等效形态特征提取及识别[J]. 光学精密工程, 2020, 28(3): 704–716.
- [8] ADRIAN R J. Multi-point optical measurements of simultaneous vectors in unsteady flow—a review[J]. *International Journal of Heat and Fluid Flow*, 1986, 7(2): 127–145.
- [9] 杨晖, 张国华, 王宇杰, 等. 密集颗粒体系的颗粒运动及结构测量技术[J]. 力学进展, 2018, 48(1): 541–590.
- [10] 段俐, 康琦, 申功炘. PIV 技术的粒子图像处理办法[J]. 北京航空航天大学学报, 2000, 26(1): 79–82.
- [11] 陈晓荣, 曹忠建, 李然, 等. 基于维诺图匹配的粒子跟踪测速法[J]. 光学仪器, 2018, 40(6): 13–20.
- [12] SIRASITTHICHOKE C, PERIVILLI S, LIDDELL M R, et al. Experimental determination of the velocity distribution in USP Apparatus 1 (basket apparatus) using Particle Image Velocimetry (PIV)[J]. *International Journal of Pharmaceutics*, 2021, 3: 100078.
- [13] SIEGEL L, HENNING A, EHRENFRIED K, et al. Investigation of the acoustic particle velocity using synchronized non-invasive measurements in the near and far field of a turbulent flow[J]. *Journal of Sound and Vibration*, 2021, 493: 115820.
- [14] DE VET S J, DE BRUYN J R. Shape of impact craters in granular media[J]. *Physical Review E*, 2007, 76(4): 041306.
- [15] DAERR A, DOUADY S. Two types of avalanche behaviour in granular media[J]. *Nature*, 1999, 399(6733): 241–243.
- [16] DELATTE D M, CRITES S T, GUTTENBERG N, et al. Segmentation convolutional neural networks for automatic crater detection on mars[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(8): 2944–2957.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//48th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015.
- [18] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHSH N, et al. UNet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(6): 1856–1867.
- [19] GUO C Y, FAN Y W, HAN Y, et al. Deep-learning-based liquid extraction algorithm for particle image velocimetry in two-phase flow experiments of an object entering water[J]. *Applied Ocean Research*, 2021, 108: 102526.
- [20] REHN E, REHN A, POSSEMIERS A. Fossil charcoal particle identification and classification by two convolutional neural networks[J]. *Quaternary Science Reviews*, 2019, 226: 106038.
- [21] ZHU L B, ZHANG H, XIANG X C, et al. Layer thickness measurement of the TRISO-coated particle based on U-Net[J]. *NDT & E International*, 2021, 121(1/3): 102468.
- [22] LOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille: JMLR. org, 2015.
- [23] HOLSCHNEIDER M, KRONLAND-MARTINET R, MORLET J, et al. A real-time algorithm for signal analysis with the help of the wavelet transform[M]//COMBES J M, GROSSMANN A, TCHAMITCHIAN P. Wavelets: Inverse Problems and Theoretical Imaging. Berlin: Springer, 1989.
- [24] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C]//4th International Conference on Learning Representations. San Juan: ICLR, 2016.
- [25] 徐胜军, 欧阳朴衍, 郭学源, 等. 多尺度特征融合空洞卷积 ResNet 遥感图像建筑物分割[J]. 光学精密工程, 2020, 28(7): 1588–1599.
- [26] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). Stanford, CA, USA: IEEE, 2016: 565–571.
- [27] ZHANG Y, LIU S J, LI C L, et al. Rethinking the dice loss for deep learning lesion segmentation in medical images[J]. *Journal of Shanghai Jiaotong University (Science)*, 2021, 26(1): 93–102.
- [28] ZHENG X J, WANG Z T, QIU Z G. Impact craters in loose granular media[J]. *The European Physical Journal E*, 2004, 13(3): 321–324.
- [29] FERREIRA C, CARDONA J, AGIMELEN O, et al. Quantification of particle size and concentration using in-line techniques and multivariate analysis[J]. *Powder Technology*, 2020, 376: 1–11.