

# 改进的DeepLabV3+模型用于震后高分遥感影像滑坡识别

赵通<sup>1</sup>, 张双成<sup>1,2,3</sup>, 何晓宁<sup>1,4</sup>, 薛博维<sup>4</sup>, 查富康<sup>1,5</sup>

1. 长安大学 地质工程与测绘学院, 西安 710054;

2. 地理信息工程国家重点实验室, 西安 710054;

3. 西部矿产资源与地质工程教育部重点实验室, 西安 710054;

4. 中科星图空间技术有限公司, 西安 710054;

5. 中国科学院空天信息创新研究院, 北京 100094

**摘要:** 利用“深度学习+遥感”在高分遥感影像上快速识别滑坡, 对于灾后应急救援工作的开展具有非常重要的现实意义。但目前为止, 公开的深度学习滑坡识别数据集较少, 难以满足相关研究人员利用深度学习方法开展滑坡识别研究的任务需求; 基于此, 本文使用谷歌地球影像和高分六号遥感影像制作并公开了一个样本数量达到10000+, 空间分辨率为2 m的深度学习滑坡数据集, 用于相关学者开展研究。此外, 为有效识别滑坡, 提取滑坡边界及细节等信息, 本文提出了一种改进的DeepLabV3+模型用于滑坡识别, 即在DeepLabV3+模型的基础上, 引入通道注意力机制特征融合模块和转置卷积来重构模型。实验结果表明, 与主流算法(FCN, U-Net, SegNet, DeepLabV3+)相比, 改进的DeepLabV3+模型在滑坡的边界及细节方面提取效果更好, 所得结果更接近于真实标签。本文的相关代码和数据可在 ([https://github.com/ZhaoTong0203/landslides\\_identification\\_model\\_code.git](https://github.com/ZhaoTong0203/landslides_identification_model_code.git)) 获得。

**关键词:** 高分遥感影像, 滑坡数据集, 深度学习, DeepLabV3+, 高分六号

**中图分类号:** TP701/P2

**引用格式:** 赵通, 张双成, 何晓宁, 薛博维, 查富康. 2024. 改进的DeepLabV3+模型用于震后高分遥感影像滑坡识别. 遥感学报, 28(9): 2293-2305

Zhao T, Zhang S C, He X N, Xue B W and Zha F K. 2024. Improved DeepLabV3+ model for landslide identification in high-resolution remote sensing images after earthquakes. National Remote Sensing Bulletin, 28(9): 2293-2305 [DOI:10.11834/jrs.20243393]

## 1 引言

地震滑坡是大陆内部山区大地震活动中最为常见的地震地质灾害类型, 其数量多且规模大。当地震震级大于4.0M<sub>l</sub>时, 地震滑坡就有可能被触发; 而强震活动, 特别是震级大于7.0M<sub>l</sub>的大地震事件中, 地震引发的次生滑坡灾害尤为显著(Keefer, 1984)。通常一次大规模地震事件会引发数千个山体滑坡, 其分布范围可达数十万平方公

里(Zhang等, 2013)。在某些大地震中, 地震滑坡造成的生命财产损失可占整个地震损失的50%以上(Keefer和Larsen, 2007)。地震滑坡常常会产生堰塞湖、道路毁坏、桥梁坍塌等灾难(Fan等, 2008), 使应急救援和现场调查难以开展, 严重影响灾后应急救援和灾情评估。以国产遥感卫星高分辨率影像为数据源, 研究面向高分辨率遥感影像滑坡识别模型, 从而实现地震滑坡空间分布及其组成要素的准确识别, 对指导地震应急救

收稿日期: 2023-09-12; 预印本: 2023-12-13

基金项目: 国家重点研发计划(编号:2020YFC1512000); 国家自然科学基金(编号:42074041); 信息工程国家重点实验室基金(编号:SKLGE2022-ZZ2-07)

第一作者简介: 赵通, 研究方向为高分遥感影像处理、深度学习。E-mail: 2021226056@chd.edu.cn

通信作者简介: 张双成, 研究方向为GNSS导航与精密定位、GNSS遥感、GNSS与InSAR灾害监测、空一天一地协同地质环境智能感知云平台及无人机LiDAR。E-mail: shuangcheng369@chd.edu.cn

关联代码和数据: [https://github.com/ZhaoTong0203/landslides\\_identification\\_model\\_code.git](https://github.com/ZhaoTong0203/landslides_identification_model_code.git)

援、灾情评估和灾后重建等工作具有重要现实意义 (Peng 等, 2017)。根据中国地震局与中国气象局发布的相关统计数据显示, 自 2016 年—2023 年间, 仅在中国大陆地区便发生 5.0 级以上地震 143 次, 共造成 344 人死亡, 直接经济损失超过 800 亿元。

传统的滑坡识别方法通常依赖于人工解译和专家经验, 存在识别效率低、主观性强以及难以处理大规模遥感数据等问题。21 世纪以来, 机器学习方法因其自动化程度较高和高适应性, 被广泛应用于大规模遥感影像滑坡识别任务中, 常用来进行滑坡识别的机器学习分类器有: 支持向量机 (Hong 等, 2016), 逻辑回归 (Chang 等, 2007), 随机森林 (Li 等, 2015; Stumpf 和 Kerle, 2011; Chen 等, 2017) 等, 这些机器学习分类器虽然在不同的实验区域得到了较好的结果, 但受模型自身条件的限制, 其泛化能力较差。2012 年, AlexNet 神经网络模型在 ImageNet 竞赛中表现突出, 展现了深度学习神经网络模型在图像分类领域中显著的技术优势, 自此, 深度学习方法被广泛应用于各行各业中。使用深度学习在遥感影像上进行滑坡识别即使用深度学习模型从大量包含滑坡标注信息的遥感影像数据 (深度学习训练数据集) 中学习遥感影像上滑坡的相关特征, 再使用训练好的深度学习模型对没有附带标注的遥感影像数据进行识别; 从而实现高效、准确的遥感影像像素级别的滑坡分类。

近年来, 国内外相关领域的学者在数据集、深度学习模型架构以及训练方法等方面做了大量的研究工作:

(1) 数据集: Ji 等 (2020) 将空间通道注意力机制运用到卷积神经网络模型上进行滑坡识别, 并公开了毕节市滑坡数据集供给相关研究者使用; 毕节市滑坡数据集是国内第一个公开的、空间分辨率为 0.8 m 的滑坡识别数据集, 但与 ImageNet 等大规模深度学习数据集相比, 其数据量较少, 只包含了 770 个滑坡影像数据。Uilo 等 (2021) 使用互联网上的公开图像创建并公开了一个包含滑坡和非滑坡图像共计 160 个样本的目标检测数据集, 并通过迁移学习方法训练 MASK R-CNN 来进行滑坡检测。Ju 等 (2020) 使用谷歌地球影像构建了一个包含 2498 处黄土滑坡的深度学习黄土滑坡样本数据库, 并使用 Mask R-CNN 目标检测模块进行黄土滑坡自动识别, 实验结果表明, Mask R-CNN

是一种快速且稳健性较好的方法, 可用于以谷歌地球影像为数据源的黄土滑坡自动识别。

(2) 模型架构: Liu 和 Wu (2016) 为了更好地捕捉滑坡图像中隐藏的更深层的特征, 提出了一种特殊的小波变换作为滑坡图像的预处理方法, 然后用一种具有多个隐藏层的深度自动编码网络来学习遥感数据中的滑坡的深层特征和表示, 并在谷歌地球影像上进行滑坡识别, 结果表明, 该方法优于传统机器学习方法。Wang 等 (2019) 使用不同时间拍摄的同一位置的遥感图像以及归一化植被指数和近红外光谱数据作为卷积神经网络模型的输入数据, 并在 2015 年中国山西大型滑坡事件和 2016 年中国福建大型滑坡事件的遥感数据上进行了验证, 结果显示, 与传统方法相比, 深度学习方法显著提高了滑坡的识别效率。Liu 等 (2020) 在 RGB 可见光波段的基础上引入坡度、坡向和数字地表模型 3 个具有地形特征信息的数据, 并通过加入残差模块来重构 U-Net 模型, 最后使用该方法对四川省九寨沟地震后的遥感影像进行滑坡识别, 实验结果表明, 该方法与传统 U-Net 模型相比, 准确率提高了 13.8%。Yang 等 (2022) 使用 GF-1 影像与数字高程模型数据进行滑坡识别研究, 利用通道融合卷积神经网络模型对滑坡样本进行分类, 解决了在深度学习训练样本数据量有限的情况下, 从遥感影像中快速确定滑坡重点区域的问题, 用以支撑大规模滑坡灾害排查。Wu 等 (2022) 通过在卷积神经网络中引入双重注意力机制进行遥感影像滑坡识别, 实验结果表明: 融入了双重注意力机制的卷积神经网络相较于单个神经网络而言, 滑坡识别的精确率更高, 且滑坡边界分割结果更接近于真实的滑坡边界。Mao 等 (2023) 使用不同的 Xception、MobileNetV2、ResNet50 等模型作为主干网络的 DeepLabV3+ 模型进行实验, 用来对比不同主干网络情形下 DeepLabV3+ 模型的滑坡识别的能力, 结果表明 ResNet50 模型作为 DeepLabV3+ 的主干网络进行滑坡识别的效果更好。

(3) 训练方法: Jiang 等 (2023) 提出了一种利用滑坡的形状、颜色、纹理等特征模拟复杂滑坡背景的数据增强方法来训练 Mask R-CNN 模型, 实验结果表明, 该方法可在训练模型时使用较少训练数据样本的前提下, 提高分割识别的准确度。考虑到深度学习模型难以从有限数量的滑坡数据集中充分学习特征和模式, Li 等 (2023) 使用迁

移学习的方法, 将 ImageNet 数据集上训练好的 ResNet50 网络及参数迁移至 LinkNet 模型上进行训练, 结果显示, 相较于传统机器学习方法和其他的深度学习方法, 使用迁移学习方法进行滑坡提取可以明显降低深度学习模型的训练难度和成本。

目前, 利用深度学习模型在高分遥感影像上进行识别滑坡已经成为了主流趋势, 但一个优秀的深度学习模型离不开大规模、高质量的数据集作为支撑, 数据集的大小和其中包含的目标类别数据标注信息质量的高低直接影响着深度学习模型的性能和应用效果。而滑坡是复杂而罕见的自然现象, 这导致了实际可用于深度学习训练的滑坡数据较少; 这种数据的不足使得滑坡识别算法的准确性和泛化性受到限制。目前为止, 公开的滑坡数据集仅有 Ji 等 (2020) 公开的毕节市滑坡数据集和 Ullo 等 (2021) 公开的滑坡目标检测数据集等, 用于滑坡识别的大规模深度学习遥感影像公开数据集较少; 基于此, 本文使用目视解译方法对地震发生后拍摄的高分六号遥感影像和谷歌地球影像进行了像素级别标注, 并使用数字高程模型和光学影像数据建立三维模型进行辅助, 用来保证滑坡标注的准确性; 最终建立了一个空间分辨率为 2 m 的公开的深度学习滑坡数据集, 其中, 数据集中共包含 11581 张影像, 远远超过了现

有公开滑坡数据集的数据量, 基本满足了绝大多数深度学习滑坡识别任务所需的训练数据量要求。据相关研究及本文的实验结果表明, 现有主流深度学习模型在进行滑坡识别任务中, DeepLabV3+ 模型的效果最佳, 但该模型使用最简单的拼接操作来融合编码模块输出的低阶特征和高阶特征, 虽然极大程度的降低了模型的复杂度, 却导致了融合效果往往达不到最优; 且该模型在上采样过程中使用双线性插值上采样, 虽然简单快速, 但往往会损失特征图的细节信息; 基于此, 为更好地识别滑坡的边界及细节信息, 提高滑坡识别的准确度, 本文在 DeepLabV3+ 网络的基础上, 引入通道注意力机制特征图融合模块和转置卷积, 提出了一种改进的 DeepLabV3+ 滑坡识别模型; 其中通道注意力机制特征图融合模块在模型训练过程中用来调整不同特征图通道之间的权重, 从而对编码结构输出的低阶特征和高阶特征进行有效的融合; 转置卷积使用可学习的卷积核来进行特征图的上采样, 这意味着模型可以学习从低分辨率特征映射生成高分辨率特征映射所需的模式, 将 DeepLabV3+ 解码结构中的线性插值上采样替换为转置卷积, 有助于模型捕获复杂的图像结构, 更大程度的识别遥感影像上滑坡的边界及细节信息; 图 1 为本文的研究流程图。

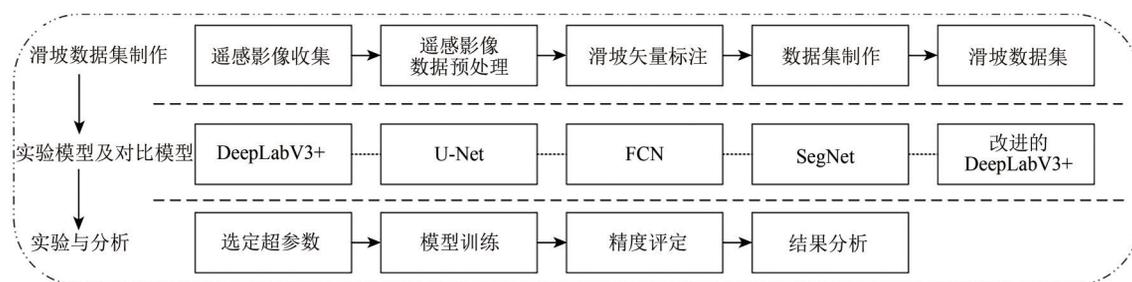


图 1 研究流程图

Fig. 1 Research flowchart

## 2 遥感影像滑坡数据集

### 2.1 数据说明

四川省位于中国西南地区, 其地形复杂多样, 西部和北部主要由高原和山地组成, 而东部则是广阔的四川盆地。受地域广阔和复杂地形的影响, 四川省气候条件呈现出多样性; 西部和北部高原山地地区属于高原山地气候, 而东部四川盆地属于亚热带季风气候。四川省位于青藏高原与亚欧

板块的交界处, 即喜马拉雅山造山带边缘, 由于印度板块持续向北移动与欧亚板块碰撞, 导致了该区域地震的频繁发生。

本文以四川省 2008 年汶川县, 2017 年九寨沟县, 2022 年泸定县发生地震后引发的滑坡为研究对象, 对地震后获取的遥感影像进行预处理和人工目视解译, 建立深度学习滑坡样本数据集。其中, 汶川县于 2008 年 5 月 12 日发生 8.0 级特大地震, 据统计, 由该地震引发的滑坡、崩塌、泥石流约有 15000 多处 (Su 等, 2008); 九寨沟县于

2017年8月8日发生7.0级地震,相关资料显示,该地震至少触发了4800处滑坡(Li等,2019);泸定县于2022年9月5日发生了6.8级地震,该次地

震共引发了超过3600处滑坡(Dai等,2023)。如表1所示,这3次地震对受灾地区造成了巨大的人员伤亡和经济损失。

表1 研究区地震灾害概览

Table 1 Overview of earthquake hazards in the study area

地震名称	震级	时间	4.0级以上余震数量	死亡人数/人	直接经济损失/亿元
汶川地震	8.0	2008-05-12	311	69227	8451
九寨沟地震	7.0	2017-08-08	3	24	80.43
泸定地震	6.8	2022-09-05	2	93	224.5

本文所获取的光学遥感影像分布范围如图2所示,其中,谷歌地球影像范围用黄色矩形框表示,

高分六号遥感影像用红色矩形框表示,共计6景影像,覆盖面积达21547 km<sup>2</sup>。

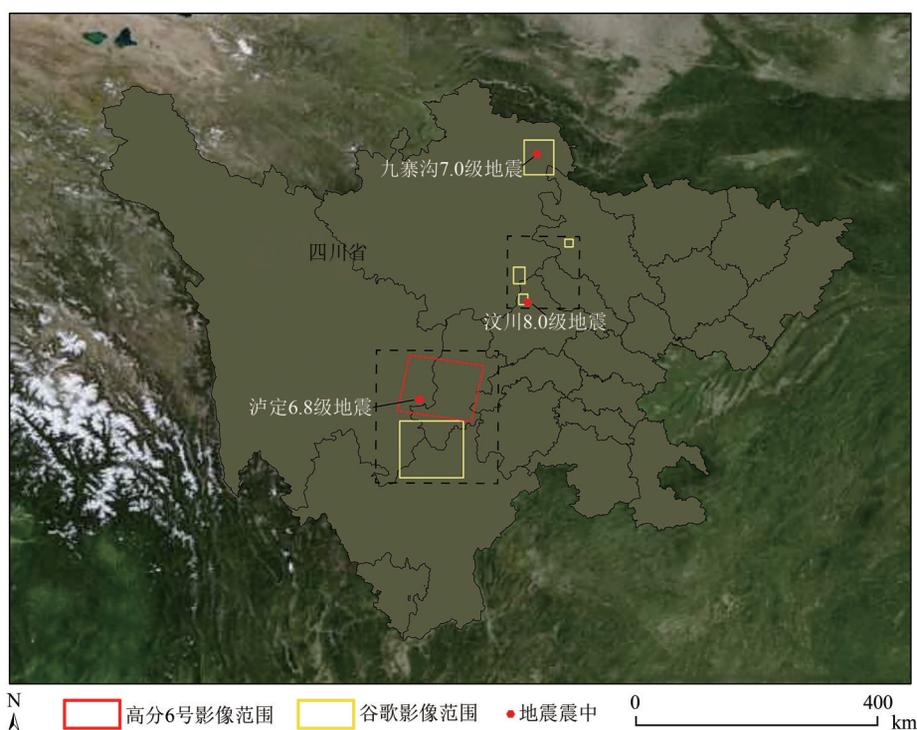


图2 遥感影像位置分布

Fig. 2 Remote sensing image location distribution

本文使用的光学影像数据包括谷歌地球影像和高分六号遥感影像。其中,谷歌地球影像空间分辨率为2 m,此外,由于本文使用的谷歌地球影像是由不同传感器拼接融合到一起的影像数据,故没有统一的成像日期;高分六号遥感影像数据来源于国家冰川冻土沙漠科学数据中心([http://](http://www.ncdc.ac.cn)

[www.ncdc.ac.cn](http://www.ncdc.ac.cn) [2023-09-12]),拍摄于2022年9月10日,空间分辨率为2 m。用于辅助绘制滑坡范围矢量数据的DEM数据来源于阿拉斯加合成孔径雷达数据中心,空间分辨率为12.5 m,垂直分辨率为1 m。数据的详细信息如表2所示。

表2 遥感影像数据说明

Table 2 Remote sensing image data description

影像名称	拍摄日期	空间分辨率/m	来源	坐标系
谷歌地球影像	—	2	谷歌地球	GCS-WGS-1984
高分六号影像	2022-09-10	2	国家冰川冻土沙漠科学数据中心	GCS-WGS-1984
DEM数据	—	12.5	阿拉斯加合成孔径雷达数据中心	GCS-WGS-1984

## 2.2 数据预处理

遥感影像在进行分析和应用之前通常需要进行预处理。通过对遥感影像进行预处理,可以提高图像质量、消除噪声和干扰、增强图像特征、减少信息损失,从而使得遥感影像能够更好地适应后续的科学研究和应用需求。

本文使用ArcGIS Pro和ENVI软件来对高分六号遥感影像进行预处理操作,具体流程如图3所示,通过辐射定标、大气校正、正射校正和几何精校正操作,提高了高分六号遥感影像的数据质量;由于谷歌地球影像其质量已满足任务需求,故不再对其进行预处理操作;为方便后续的滑坡矢量数据标注工作,在预处理完光学影像之后,需对DEM数据进行裁剪,使其范围与光学影像范围保持一致。

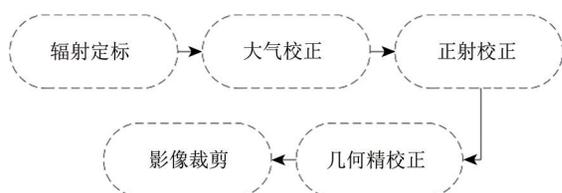


图3 遥感影像预处理流程

Fig. 3 Remote sensing image preprocessing workflow

## 2.3 数据标注

影像数据滑坡标注即对预处理后的遥感影像进行人工目视解译,勾勒出滑坡的边界范围,再对所得结果做格式转换、数据检查等一系列后续处理的工作。

本文首先使用ArcGIS Pro对光学遥感影像数据和DEM数据构建三维立体模型作为辅助参考,然后在光学影像上对滑坡边界形状进行勾勒,如图4所示。

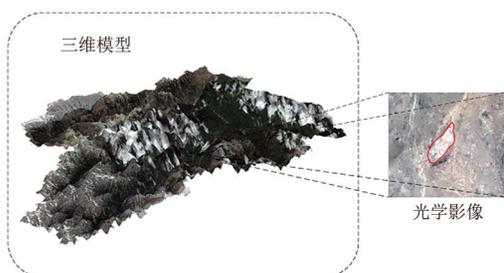
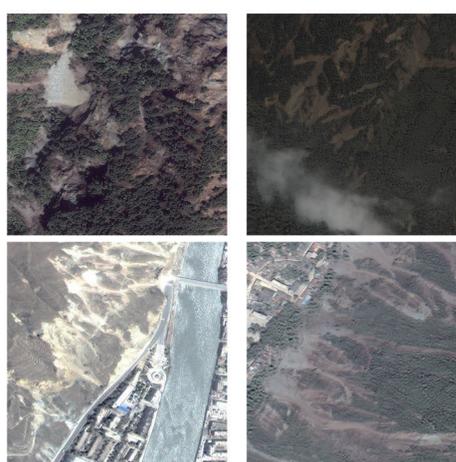


图4 三维模型辅助绘制

Fig. 4 Three-dimensional model-assisted drawing

在对标注好的影像数据进行格式转换以及裁剪后;数据集中包含大量需要进行细节修正的困难样本(包含大量滑坡细节信息和复杂背景信息

的样本数据)和需要删除的无效样本(包含大范围云雾遮挡、影像畸变、NoData数据等);如图5所示,其中图5(a)为4景困难样本本影像数据,其包含大量滑坡细节信息或背景信息包含较多其他类型的地物,在绘制标签过程中,一般需要进行修正;图5(b)为简单样本,其包含的滑坡细节信息较少且背景信息简单;图5(c)为遥感影像裁剪过程NoData样本数据,图5(d)为被大范围云雾遮挡的样本数据,图5(e)为影像畸变的样本数据,一般对图5(c)、图5(d)、图5(e)需要进行删除操作。



(a) 困难样本

(a) Difficult samples



(b) 简单样本

(b) Simple sample

(c) NoData样本

(c) NoData sample



(d) 云雾遮挡  
(d) Cloud and fog  
obstruction

(e) 影像畸变  
(e) Image  
distortion

图5 样本示例

Fig. 5 Sample examples

为保证数据集中滑坡样本数据的质量,本文使用由MIT (Massachusetts Institute of Technology)

开发的开源 Labelme 工具 (Sager 等, 2021) 进行了多轮筛选检查, 并编写相应的扩展代码来对标签数据做相应的人工筛选删除, 修正等操作, 制作数据集的具体流程如图 6 所示。

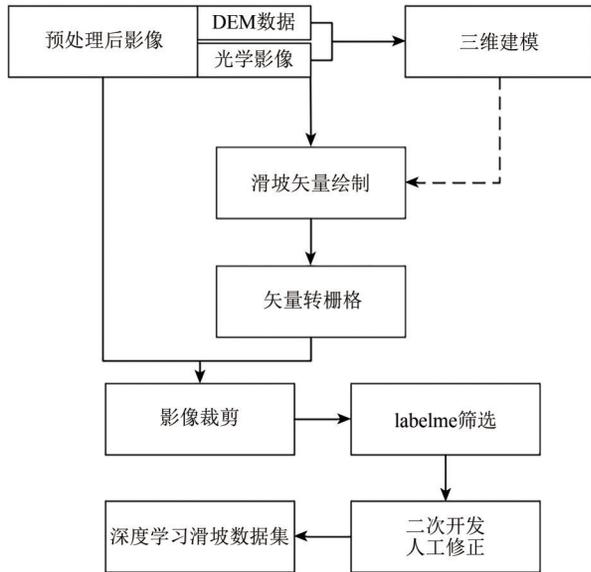


图 6 数据集制作流程

Fig. 6 Dataset creation process

### 2.4 数据集统计分析说明

本文制作并公开的数据集共包含两个部分: 初始数据和深度学习数据。其中, 初始数据包含在 ArcGIS Pro 和 ENVI 软件下预处理完成的光学影像数据、DEM 数据和绘制完成的矢量文件数据; 相关研究者可以在其基础上按照不同的应用进行进一步处理; 深度学习数据为经处理后可直接用于深度学习任务的数据集。

经 ArcGIS Pro 软件和相应的扩展代码统计分析, 在本数据集中, 滑坡总面积为 217.64 km<sup>2</sup>, 非滑坡地区总面积为 2818.250 km<sup>2</sup>, 非滑坡区域主要地物为: 植被、道路、建筑物和裸地等; 数据集共占遥感影像覆盖总面积的 14.09%。

为方便后续学者进行目标检测任务的相关研究, 本研究使用语义分割标签数据和相关的标签转换代码, 生成了本数据集中滑坡数据所对应的目标检测标签数据。图 7 为深度学习数据部分的存储目录结构, 共包含 3 个文件夹, 其中 Train 文件夹存储着对应深度学习训练部分的数据, Valid 文件夹存储着对应深度学习验证部分的数据, Test 文件夹存储着对应深度学习测试部分的数据。本研

究根据训练集: 验证集: 测试集=80%: 10%: 10%的比例, 将数据随机抽取划分, 其中训练集包含 9265 组数据; 验证集包含 1158 组数据; 测试集包含 1158 组数据。本数据集共有 11581 组数据, 每组数据又包含遥感影像数据, 以及对应的语义分割标签文件和目标检测标签文件, 在语义分割标签文件中, 像素灰度值为 255 代表滑坡体范围或边界, 像素灰度值为 0 代表背景, 标签文件以 TIF 格式存储, 尺寸大小均为 512×512; 在目标检测标签文件中, 使用四个浮点数来表示目标检测矩形框在图中的相对位置, 目标检测标签文件以 txt 格式进行存储, 图 8 为数据集中一组数据的样例。

```

|- Remote Sensing Landslide Dataset
| | |- Train
| | | | |- Image # 光学遥感影像
| | | | |- Object Detection Label # 目标检测标签
| | | | |- Semantic Segmentation Label # 语义分割标签
| | |- Valid
| | | | |- Image
| | | | |- Object Detection Label
| | | | |- Semantic Segmentation Label
| | |- Test
| | | | |- Image
| | | | |- Object Detection Label
| | | | |- Semantic Segmentation Label

```

图 7 深度学习数据集存储目录结构

Fig. 7 Directory structure for deep learning dataset storage

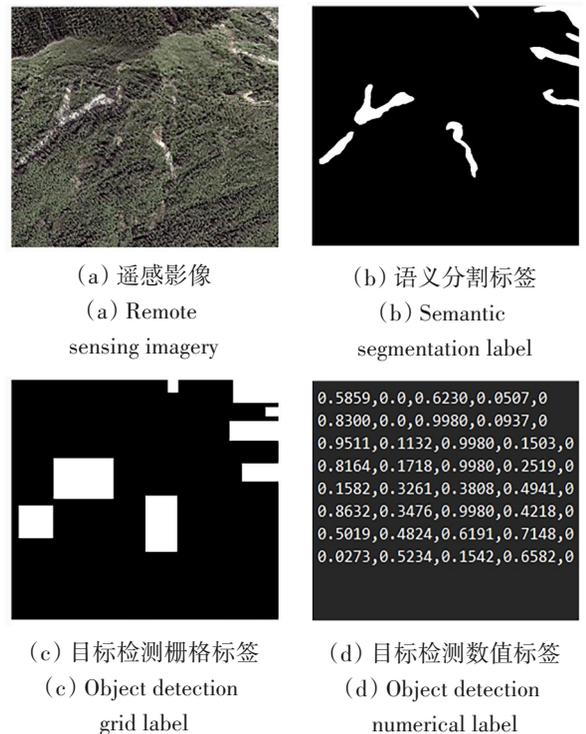


图 8 深度学习滑坡数据集示例

Fig. 8 Example of deep learning landslide dataset

### 3 研究方法

#### 3.1 DeepLabV3+网络

DeepLabV3+网络是由 Google Brain 团队于 2018 年提出的一种用于深度学习语义分割任务的神经网络结构 (Chen 等, 2018), 其网络架构图如图 9 所示, 主要组成部分包括: 骨干网络、空洞空间金字塔池化 (ASPP) 和解码器模块; 其中, 骨干

网络作为特征提取器, 即编码结构; ASPP 模块利用多个平行的空洞卷积分支来捕获不同感受野的上下文信息, 这些平行的分支可以在不同的尺度上对特征图进行卷积, 从而允许网络同时感知局部和全局的语义信息; 解码器模块通过上采样和与骨干网络对应层级的特征图进行融合, 再通过线性插值上采样方法将低分辨率的特征图映射为与输入图像相同大小的分割结果图。

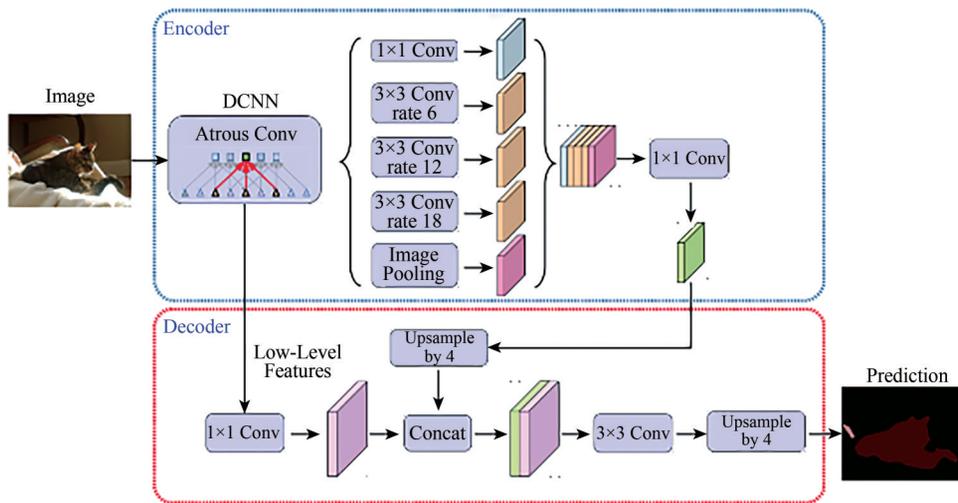


图 9 DeepLabV3+网络架构  
Fig. 9 DeepLabV3+ network architecture

#### 3.2 线性插值上采样与转置卷积上采样

线性插值上采样和转置卷积上采样是在深度学习和图像处理中常用的两种上采样技术, 其作用是将低分辨率输入数据转变为高分辨率输出数据。线性插值上采样是根据已知的数据点之间的线性关系来估计新数据点的值。在 DeepLabV3+网络解码模块中, 使用双线性插值方法来生成更高分辨率的特征图, 其优点是简单快速, 但在某些情况下可能无法捕获复杂的图像结构, 从而损失一些图像的细节信息。

转置卷积使用内部参数在训练过程中可不断调整的卷积核来进行上采样操作, 即在输入特征图上滑动一个内部参数可学习的卷积核, 在输出特征图上生成更多的像素。在深度学习语义分割任务中, 使用转置卷积可以更好地处理复杂图像结构和语义信息。

#### 3.3 通道注意力机制特征图融合模块

特征图融合模块是深度学习中常见的一种组件, 用于将来自不同层级或不同分支的特征图进行融合, 以增强模型的性能。特征图融合模块通

常用于处理多尺度信息、多分支信息或跳跃连接的情况。常见的特征图融合方法有: 通道拼接融合、残差融合和注意力机制融合等。

本文使用通道注意力机制融合特征图。通道注意力机制特征图融合的基本思想是, 不同通道的特征图可能具有不同的重要性, 通过在模型训练过程中自动学习, 从而确定哪些特征通道对于解决相应任务是最重要的; 再对输入特征的不同通道进行加权组合, 以突出最相关的特征通道, 抑制不相关的通道, 从而实现特征融合的目的。本文所使用的通道注意力机制特征图融合模块结构如图 10 所示。

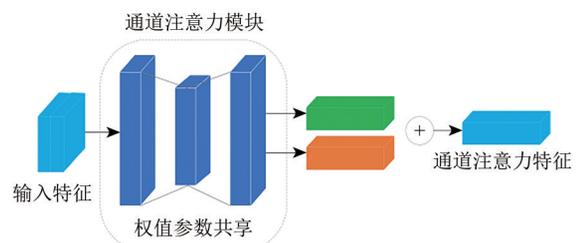


图 10 通道注意力机制特征融合模块  
Fig. 10 Channel attention mechanism feature fusion module

### 3.4 改进的DeepLabV3+网络

本文提出的模型以传统的DeepLabV3+网络结构为基本模型架构；其中，为加速模型训练，本文使用迁移学习方法，将ImageNet数据集上训练好的ResNet50模型的主干网络架构及其参数迁移到DeepLabV3+网络模型中的编码结构中；在解码结

构中，本文使用转置卷积来替换基础DeepLabV3+网络结构中的线性插值操作，进行特征图的上采样处理；此外，为更好的融合编码模块提供的低阶语义信息和高阶语义信息，本文使用通道注意力机制将其融合，具体网络结构如图11所示。

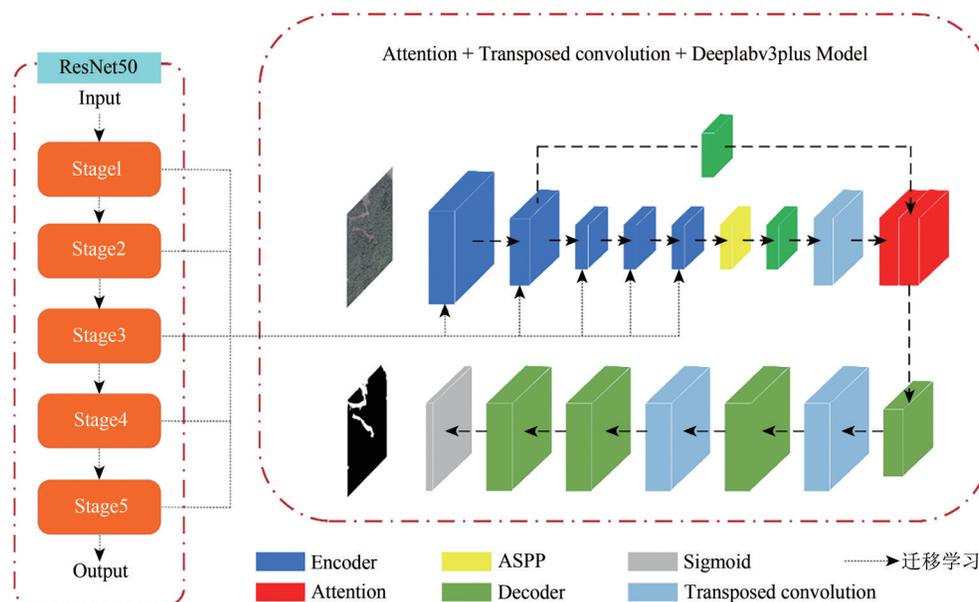


图11 改进的DeepLabV3+网络结构

Fig. 11 Improved DeepLabV3+ network architecture

## 4 实验与分析

### 4.1 模型训练设置

本文实验硬件配置如下：处理器 Intel (R) Core (TM) i7-12650H，运行内存 16 GB，GPU 型号为 NVIDIA GeForce RTX 4060 Laptop (8 G)。深度学习框架为 Pytorch2.0.0，其他辅助软件包括 PyCharm 和 Anaconda；实验的超参数设置如表3所示。

表3 超参数设置

Table 3 Hyperparameter setting

参数	设置
Image Size	256×256
Batch Size	8
Max Epoch	100
Optimizer	Adam
Learning Rate	0.0001
损失函数	IouLoss

图像尺寸 (Image size) 是指经数据增强处理后，初始输入模型图片的尺寸大小，本文所制作

并公开的数据集中图像尺寸为 512×512，但受计算机硬件环境的限制，本文在数据增强过程中将输入图像的图像尺寸统一缩放为 256×256。本文使用 IouLoss 作为损失函数，优化方法使用 Adam 自适应学习率优化算法，用于训练深度学习模型，学习率为 0.0001。

### 4.2 评价指标

混淆矩阵是用于衡量分类模型性能的一种常见工具，特别在机器学习和统计学中广泛应用。它是一个二维表格，用于比较模型预测结果与真实标签之间的差异。混淆矩阵的结构如表4所示。以二分类问题为例，将类别 A 称为正例，类别 B 称为反例，模型预测正确记作真，预测错误记作假，可组合为 4 个基础元素，如下：真正例 (TP)：模型正确地将正例样本分类为正例，即模型预测为 A 类，实际也为 A 类；真反例 (TN)：模型正确地将反例样本分类为反例，即模型预测为 B 类，实际也为 B 类；假正例 (FP)：模型错误地将反例样本分类为正

例, 即模型预测为 A 类, 实际为 B 类; 假反例 (FN): 模型错误地将正例样本分类为反例, 即模型预测为 B 类, 实际为 A 类。

表 4 混淆矩阵  
Table 4 Confusion matrix

真实情况	预测结果	
	正例	反例
正例	TP(真正例)	FN(假反例)
反例	FP(假正例)	TN(真反例)

使用混淆矩阵可以计算多种二级分类指标, 常见的二级分类指标有: 召回率 (Recall), 精确率 (Precision), F1 Score 和交并比 (IOU) 等; 其中, Recall 用来衡量模型对正例样本的识别能力, Precision 用来衡量模型对于预测为正例的样本的准确性, F1 Score 是精确率和召回率的调和平均数, 用于综合评估模型的性能; 其计算公式如下所示:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

IOU 是一种常用的用于评估目标检测和图像分割模型性能的指标。它衡量了预测区域与真实区

域之间的重叠程度, 其计算公式如下:

$$\text{IOU}(M_i, M_p) = \frac{M_i \cap M_p}{M_i \cup M_p} \quad (4)$$

式中,  $M_i$  是真实分割掩码,  $M_p$  是预测分割掩码;  $M_i \cap M_p$  表示预测分割掩码和真实分割掩码的交集区域的面积,  $M_i \cup M_p$  表示它们的并集区域的面积。此外, 像素准确率 (Accuracy) 是分类任务中最常见的一级指标之一, 用于衡量分类模型对所有样本的分类正确率, 其计算公式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (5)$$

本文使用一级评价指标像素准确率以及上述所有二级指标相对应的目标类别和背景类别评价指标的均值作为实验模型分割结果的评价指标。

### 4.3 结果分析

本文使用常用的语义分割网络 FCN、SegNet、U-Net、DeepLabV3+ 作为对照实验模型, 其训练过程的超参数设置与本研究所提出的改进的 DeepLabV3+ 训练过程中设置的超参数一致。实验结果表明, SegNet 在滑坡检测中性能最差, 其他常见的语义分割模型在滑坡语义分割任务中表现出相似的性能。各模型用于滑坡检测在测试集上的结果评价指标如表 5 所示。

表 5 模型评价指标对比

Table 5 Comparison of evaluation index models

网络模型	召回率	精确率	F1 Score	像素准确率	平均交并比
FCN	89.48	88.82	88.56	98.78	85.20
U-Net	94.15	84.73	87.72	98.36	82.32
SegNet	83.59	87.49	84.16	98.04	79.12
DeepLabV3+	95.05	89.11	91.16	98.74	86.60
改进的 DeepLabV3+	92.47	90.35	90.87	98.91	87.24

实验结果表明, 本文所提出的改进的 DeepLabV3+ 模型在精确率, 像素准确率, 平均交并比指标上皆优于其他模型; 除了召回率 (92.47%) 和 F1 Score (90.87%), 其中 DeepLabv3+ 获得了最好的召回率 (95.05%) 和 F1 Score (91.16%)。对于精确率, 改进的 DeepLabV3+ 模型是所有模型中唯一得分超过 90% 的模型。与 DeepLabv3+ 相比, 改进的 DeepLabV3+ 模型的精确率提高了 1.24%, 像素准确率提高了 0.17%, 平均交并比提高了 0.64%。

在使用深度学习语义分割模型识别遥感影像上的滑坡时, 因为单幅遥感影像范围较大, 直接对其进行处理需大量计算资源, 通常需要将遥感

影像进行分块处理后再进行识别。而在遥感影像分块过程中, 由于分块过程的随机性和遥感影像上滑坡背景的复杂性, 分块后的遥感影像上的滑坡的形状、背景等也呈现出多样性; 部分分块后的遥感影像包含的信息较少, 如图 12 中的 Image 所示, 在这些简单样本中, 只包含极个别的滑坡或滑坡的一部分, 背景信息较为单一; 而有些分块后的遥感影像包含的信息较多, 如图 13 中的 Image 所示, 在这困难样本中, 包含的滑坡细节信息较为复杂, 或背景中包含多种类型的地物。图 12 展示了测试数据集中部分滑坡简单样本的影像数据、对应的真实标签 (label) 和实验模型以及各

对照实验模型的预测结果；其中，黄色矩形框为各模型预测结果与真实标签相比具有显著差异的区域；可以看出，与其他常见语义分割模型相比，本文提出的改进的DeepLabV3+模型在测试集的简单样本中识别出的滑坡结果准确率更高，识别错误的范围更小。图13展示了测试数据集中部分滑坡困难样本的影像数据、label和实验模型以及各对照实验模型的预测结果；其中，在图13(a)、图13(c)和图13(d)中，虽然滑坡的背景信息较为单一，但包含多个滑坡，且滑坡边界的细节信息较为复杂；从预测结果可以看出，本文所提

出的改进的DeepLabV3+模型可以很好的识别出滑坡边界的细节，且与其他常见语义分割模型相比，识别错误区域的范围较小（黄色矩形框标记范围）；图13(b)图与图13(a)、图13(c)、图13(d)图相比，滑坡数量较少，但其背景信息更为复杂，包含道路、水体、建筑物等多种地物类型，且在该图右下方区域，滑坡对道路造成了一定程度的损毁，从预测结果可以看出，本文所提出的改进的DeepLabV3+模型未受到其他地物的影响，完整的识别出了滑坡边界细节，而其他语义分割模型的识别结果或多或少出现了一些细节上的错误。

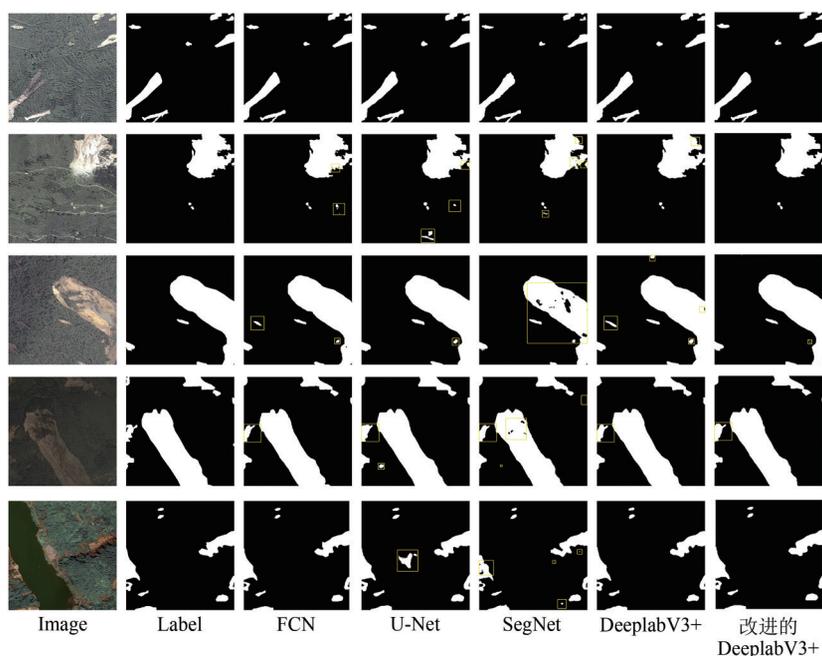


图12 不同语义分割模型的滑坡简单样本预测结果对比

Fig. 12 Comparison of landslide simple sample prediction results of different semantic segmentation models

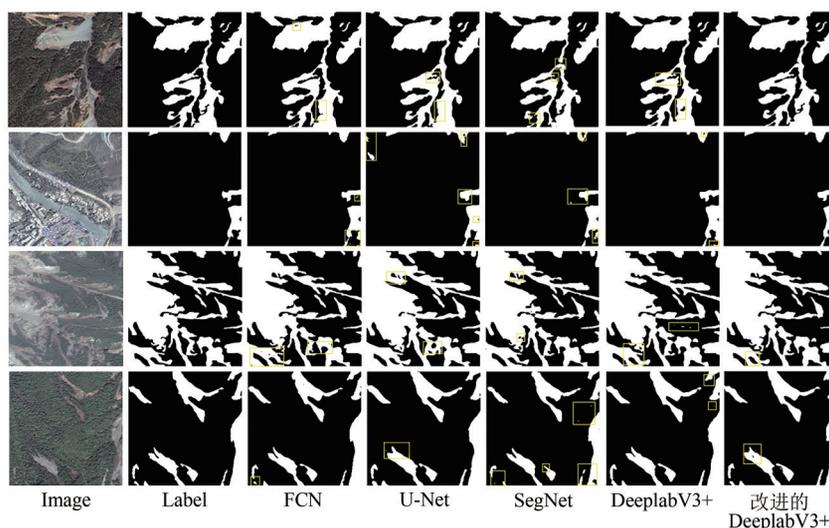


图13 不同语义分割模型的滑坡困难样本预测结果对比

Fig. 13 Comparison of prediction results of different semantic segmentation models for landslide difficulty samples

## 5 结 论

本文制作并公开了一个包含 11581 张样本数据的大规模震后高分遥感影像滑坡数据集,大规模数据集有助于训练更复杂、更准确的深度学习模型,提高模型的性能和泛化能力;该数据集在实际应用中有助于推动应用创新、提高数据质量,从而更好地应对地质滑坡等自然灾害带来的挑战,保护人民的生命和财产安全。本文提出了一种改进的 DeepLabV3+模型用于滑坡识别:在编码模块,利用迁移学习方法使用在 ImageNet 数据集上训练好的 ResNet50 模型先进行特征提取;再使用通道注意力机制融合编码模块输出的高阶特征和低阶特征;在解码模块,将基础 DeepLabV3+网络结构中的线性插值上采样替换为转置卷积,增加可学习的模型参数量;使得模型可进行更高精度的滑坡提取。实验结果表明:相较于其他主流的深度学习语义分割方法,利用本文提出的改进的 DeepLabV3+模型在滑坡识别任务中识别的结果更接近于人眼所判别的滑坡边界;该方法可用于震后高分遥感影像滑坡识别,有助于滑坡灾害详查、灾情预警以及灾后应急救援辅助决策等工作。

## 参考文献(References)

- Chang K T, Chiang S H and Hsu M L. 2007. Modeling typhoon- and earthquake-induced landslides in a mountainous watershed using logistic regression. *Geomorphology*, 89(3/4): 335-347 [DOI: 10.1016/j.geomorph.2006.12.011]
- Chen L C, Zhu Y K, Papandreou G, Schroff F and Adam H. 2018. Encoder-Decoder with atrous separable convolution for semantic image segmentation//Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich: Springer: 833-851 [DOI: 10.1007/978-3-030-01234-2\_49]
- Chen T, Trinder J C and Niu R Q. 2017. Object-oriented landslide mapping using ZY-3 satellite imagery, Random Forest and mathematical morphology, for the Three-Gorges Reservoir, China. *Remote Sensing*, 9(4): 333 [DOI: 10.3390/rs9040333]
- Dai L X, Fan X M, Wang X, Fang C Y, Zou C B, Tang X C, Wei Z L, Xia M Y, Wang D and Xu Q. 2023. Coseismic landslides triggered by the 2022 Luding Ms6.8 earthquake, China. *Landslides*, 20(6): 1277-1292 [DOI: 10.1007/s10346-023-02061-3]
- Fan J R, Zhang J Q, Tian B W, Yan D and Tao H P. 2008. Investigation to the damaged farmland as a result of disasters induced by Wenchuan earthquake based on remote sensing: a case study of Tangjishan area, Beichuan county, Sichuan province. *Journal of Remote Sensing (in Chinese)*, 12(6): 917-924 (范建容, 张建强, 田兵伟, 严冬, 陶和平. 2008. 汶川地震次生灾害毁坏耕地的遥感快速评估方法——以北川县唐家山地区为例. *遥感学报*, 12(6): 917-924) [DOI: 10.11834/jrs.200806123]
- Hong H Y, Pradhan B, Jebur M N, Bui D T, Xu C and Akgun A. 2016. Spatial prediction of landslide hazard at the Luxi area (China) using support vector machines. *Environmental Earth Sciences*, 75(1): 40 [DOI: 10.1007/s12665-015-4866-9]
- Ji S P, Yu D W, Shen C Y, Li W L and Xu Q. 2020. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks. *Landslides*, 17(6): 1337-1352 [DOI: 10.1007/s10346-020-01353-2]
- Jiang W D, Xi J B, Li Z H, Ding M T, Yang L G, Xie D S. 2023. Landslide detection and segmentation using Mask R-CNN with simulated hard samples. *Geomatics and Information Science of Wuhan University*, 48(12): 1931-1942 (姜冬冬, 席江波, 李振洪, 丁明涛, 杨立功, 谢大师. 2023. 模拟困难样本的Mask R-CNN滑坡分割识别. *武汉大学学报(信息科学版)*, 48(12): 1931-1942) [DOI: 10.13203/j.whugis.20200692]
- Ju Y Z, Xu Q, Jin S C, Li W L, Dong X J and Guo Q H. 2020. Automatic object detection of loess landslide based on deep learning. *Geomatics and Information Science of Wuhan University*, 45(11): 1747-1755 (巨袁臻, 许强, 金时超, 李为乐, 董秀军, 郭庆华. 2020. 使用深度学习方法实现黄土滑坡自动识别. *武汉大学学报(信息科学版)*, 45(11): 1747-1755) [DOI: 10.13203/j.whugis.20200132]
- Keefer D K. 1984. Landslides caused by earthquakes. *Geological Society of America Bulletin*, 95(4): 406-421
- Keefer D K and Larsen M C. 2007. Assessing landslide hazards. *Science*, 316(5828): 1136-1138 [DOI: 10.1126/science.1143308]
- Li Q, Zhang J F, Luo Y and Jiao Q S. 2019. Recognition of earthquake-induced landslide and spatial distribution patterns triggered by the Jiuzhaigou earthquake in August 8, 2017. *Journal of Remote Sensing (in Chinese)*, 23(4): 785-795 (李强, 张景发, 罗毅, 焦其松. 2019. 2017年“8.8”九寨沟地震滑坡自动识别与空间分布特征. *遥感学报*, 23(4): 785-795) [DOI: 10.11834/jrs.20197345]
- Li X J, Cheng X W, Chen W T, Chen G and Liu S W. 2015. Identification of forested landslides using LiDAR data, object-based image analysis, and machine learning algorithms. *Remote Sensing*, 7(8): 9705-9726 [DOI: 10.3390/rs70809705]
- Li Z, Li S S and Ge X Q. 2023. Transfer learning method for landslide extraction from GF-1 images after the Wenchuan earthquake. *National Remote Sensing Bulletin*, 27(8): 1866-1875 (李震, 李山山, 葛小青. 2023. 迁移学习方法提取高分一号影像汶川地震震后滑坡. *遥感学报*, 27(8): 1866-1875) [DOI: 10.11834/jrs.20211020]
- Liu P, Wei Y M, Wang Q J, Chen Y and Xie J J. 2020. Research on post-earthquake landslide extraction algorithm based on improved U-Net model. *Remote Sensing*, 12(5): 894 [DOI: 10.3390/rs12050894]

- Liu Y and Wu L Z. 2016. Geological disaster recognition on optical remote sensing images using deep learning. *Procedia Computer Science*, 91: 566-575 [DOI: 10.1016/j.procs.2016.07.144]
- Mao J Q, He J, Liu G and Fu R. 2023. Landslide recognition based on improved DeepLabV3+ algorithm. *Journal of Natural Disasters*, 32(2): 227-234 (毛佳琪, 何敬, 刘刚, 付饶. 2023. 基于改进的DeepLabV3+算法滑坡识别. *自然灾害学报*, 32(2): 227-234) [DOI: 10.13577/j.jnd.2023.0224]
- Peng L, Xu S N, Mei J J and Su F H. 2017. Earthquake-induced landslide recognition using high-resolution remote sensing images. *Journal of Remote Sensing (in Chinese)*, 21(4): 509-518 (彭令, 徐素宁, 梅军军, 苏凤环. 2017. 地震滑坡高分辨率遥感影像识别. *遥感学报*, 21(4): 509-518) [DOI: 10.11834/jrs.20176176]
- Sager C, Janiesch C and Zschech P. 2021. A survey of image labelling for computer vision applications. *Journal of Business Analytics*, 4(2): 91-110 [DOI: 10.1080/2573234X.2021.1908861]
- Stumpf A and Kerle N. 2011. Object-oriented mapping of landslides using Random Forests. *Remote Sensing of Environment*, 115(10): 2564-2577 [DOI: 10.1016/j.rse.2011.05.013]
- Su F H, Liu H J and Han Y S. 2008. The extraction of mountain hazard induced by Wenchuan earthquake and analysis of its distributing characteristic. *Journal of Remote Sensing (in Chinese)*, 12(6): 956-963 (苏凤环, 刘洪江, 韩用顺. 2008. 汶川地震山地灾害遥感快速提取及其分布特点分析. *遥感学报*, 12(6): 956-963) [DOI: 10.11834/jrs.200806128]
- Ullo S L, Mohan A, Sebastianelli A, Ahamed S E, Kumar B, Dwivedi R and Sinha G R. 2021. A new Mask R-CNN-based method for improved landslide detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 3799-3810 [DOI: 10.1109/JSTARS.2021.3064981]
- Wang Y, Wang X F and Jian J F. 2019. Remote sensing landslide recognition based on convolutional neural network. *Mathematical Problems in Engineering*, 2019: 8389368 [DOI: 10.1155/2019/8389368]
- Wu Q, Zhou C B, Huang F M and Yao C. 2022. Optimization of the landslide identification method based on a dual attention mechanism. *Bulletin of Geological Science and Technology*, 41(2): 246-253 (吴琪, 周创兵, 黄发明, 姚池. 2022. 基于双重注意力机制的滑坡识别方法优化. *地质科技通报*, 41(2): 246-253) [DOI: 10.19509/j.cnki.dzkg.2022.0053]
- Yang Z Y, Han L Y, Zheng X X, Li W J, Feng L, Wang Y and Yang Y P. 2022. Landslide identification using remote sensing images and DEM based on convolutional neural network: a case study of loess landslide. *Remote Sensing for Natural Resources*, 34(2): 224-230 (杨昭颖, 韩灵怡, 郑向向, 李文吉, 冯磊, 王轶, 杨永鹏. 2022. 基于卷积神经网络的遥感影像及DEM滑坡识别——以黄土滑坡为例. *自然资源遥感*, 34(2): 224-230) [DOI: 10.6046/zrzyg.2021204]
- Zhang D, Wu Z H, Li J C and Jiang Y. 2013. An overview on earthquake-induced landslide research. *Journal of Geomechanics*, 19(3): 225-241 (张铎, 吴中海, 李家存, 蒋瑶. 2013. 国内外地震滑坡研究综述. *地质力学学报*, 19(3): 225-241) [DOI: 10.3969/j.issn.1006-6616.2013.03.001]

## Improved DeepLabV3+ model for landslide identification in high-resolution remote sensing images after earthquakes

ZHAO Tong<sup>1</sup>, ZHANG Shuangcheng<sup>1,2,3</sup>, HE Xiaoning<sup>1,4</sup>, XUE Bowei<sup>4</sup>, ZHA Fukang<sup>1,5</sup>

1. College of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China;

2. State Key Laboratory of Geo-Information Engineering, Xi'an 710054, China;

3. Key Laboratory of Western China's Mineral Resource and Geological Engineering, Ministry of Education, Xi'an 710054, China;

4. Geovis Spatial Technology Co., Ltd, Xi'an 710054, China;

5. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China

**Abstract:** Postearthquake emergency rescue must use the method of “deep learning+remote sensing” to identify landslides from high-resolution remote sensing images quickly after an earthquake. However, an excellent deep learning model cannot be separated from a large-scale, high-quality dataset as a support. The size of the dataset and the quality of the target category data annotation information contained in it directly affect the performance and application effect of the deep learning model. So far, a few public datasets of deep learning landslide identification are available; however, they hardly meet the task requirements of researchers who use deep learning methods to conduct landslide identification. Thus, this study uses the visual interpretation method to annotate the pixel level of GF-6 remote sensing image and Google Earth image taken after the earthquake and uses the digital elevation model and optical image data to establish a three-dimensional model to assist and ensure the accuracy of landslide annotation. Finally, a public deep learning landslide dataset with a spatial resolution of 2 m is established; it can be used to train deep learning semantic segmentation and target detection models. The dataset contains 11581 groups of data, among which the training set contains 9265 groups of data; the validation set contains 1158 groups of data, and the test set contains 1158 groups of data, which far exceeds the data volume of the existing public landslide dataset and basically meets the training data

volume requirements of most deep learning landslide identification tasks. In addition, to recognize the boundary and detail information of landslides better and improve the accuracy of landslide recognition, this study proposes an improved DeepLabV3+ landslide recognition model based on DeepLabV3+ network by introducing channel attention mechanism, feature map fusion module, and transposed convolution. The feature map fusion module of the channel attention mechanism is used to adjust the weight between different feature map channels in the model training process to fuse effectively the low-order and high-order feature output by the coding structure. The transposed convolution uses a learnable convolution kernel to upsample the feature map to process complex image structure and semantic information well. During model training, this study uses the transfer learning method to transfer the backbone network architecture and its parameters of the ResNet50 model trained on the ImageNet dataset to the encoder structure of the DeepLabV3+ network model to accelerate the training of the model. Experimental results show that compared with the mainstream algorithms (FCN, U-Net, SegNet, DeepLabV3+), the improved DeepLabV3+ model has better extraction effect on the boundary and details of the landslide, and the results are closer to the real label; among them, MIOU is 87.24%, recall is 92.47%, precision is 90.35%, F1 score is 90.87%, and pixel accuracy is 98.91%. The code and data for this article are available at [https://github.com/ZhaoTong0203/landslides\\_identification\\_model\\_code.git](https://github.com/ZhaoTong0203/landslides_identification_model_code.git). This research provides robust support for the advancement of deep learning in landslide identification and offers substantial practical assistance for postearthquake emergency rescue efforts.

**Key words:** high-resolution remote sensing images, landslide data sets, deep learning, DeepLabV3+, GF-6

**Supported by** National Key Research and Development Program of China (No. 2020YFC1512000); National Natural Science Foundation of China Projects (No. 42074041); State Key Laboratory of Geo-Information Engineering (No. SKLGIE2022-ZZ2-07)