

# 基于 MultiU-EGANet 模型的同震滑坡智能识别

张灿灿<sup>1,2</sup>, 丁明涛<sup>1,2,3,4,5\*</sup>, 申传庆<sup>6</sup>, 李云龙<sup>1,2</sup>, 李振洪<sup>1,2,3,4</sup>, 余琛<sup>1,2,3,4</sup>

1 长安大学地质工程与测绘学院, 陕西 西安, 710054

2 长安大学地学与卫星大数据研究中心, 陕西 西安, 710054

3 黄土科学全国重点实验室, 陕西 西安, 710054

4 西部矿产资源与地质工程教育部重点实验室, 陕西 西安, 710054

5 智慧地球重点实验室, 北京, 100029

6 自然资源部陕西基础地理信息中心, 陕西 西安, 710054

**摘要:** 同震滑坡制图在应急救援和灾害评估中具有至关重要的作用。为更好进行滑坡识别, 本文提出了一种新的改进模型—MultiU-EGANet。该模型以 U-Net 模型为基线模型, 通过引入 MultiRes 模块, 实现对不同尺度特征信息的提取; 引入边缘引导注意力模块 (Edge-Guided Attention, EGA), 通过拉普拉斯算子强化滑坡边界, 从而提高模型对边界的分割精度; 结合 Dice loss 和 Focal loss 构造复合损失函数, 进一步增强模型的鲁棒性。本文基于九寨沟地区滑坡数据进行实验, 结果表明改进模型相较于基线模型, 滑坡识别精度得到了明显提升。此外, 基于北海道地区滑坡数据进行模型对比实验, 结果表明, 所提出方法相较于其他现有模型在滑坡识别任务中表现更为优越, F1 值分别提升了 33.31%、5.45%、2.31%、2.18%。实验结果充分证明了所提出方法在同震滑坡识别中的有效性。

**关键词:** 同震滑坡; 变化检测; 多尺度; 边缘引导

中图分类号: P237

收稿日期: 2024-12-31

## Intelligent recognition of coseismic landslides based on MultiU-EGANet model

Zhang Cancan<sup>1,2</sup>, Ding Mingtao<sup>1,2,3,4,5\*</sup>, Shen Chuanqing<sup>6</sup>, Li Yunlong<sup>1,2</sup>, Li Zhenhong<sup>1,2,3,4</sup>, Yu Chen<sup>1,2,3,4</sup>

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

2 Big Data Center for Geosciences and Satellites (BDCGS), Chang'an University, Xi'an 710054,

China

基金项目: 国家自然科学基金 (42374027); 智慧地球重点实验室基金 (KF2023YB04-01); 浙江省“尖兵”“领雁”研发攻关计划项目 (2023C03177); 陕西省科技创新团队 (2021TD-51); 陕西省地学大数据与地质灾害防治创新团队 (2022)。

作者简介: 张灿灿 (2000—), 女, 硕士研究生, 主要从事深度学习和其在滑坡灾害方面的研究。ORCID: 0009-0002-0240-3885。

E-mail: 2022126015@chd.edu.cn.

\*通讯作者: 丁明涛 (1983—), 男, 博士, 教授, 主要从事机器学习、遥感影像处理研究。ORCID: 0000-0003-1210-9188。E-mail: mingtaoding@chd.edu.cn.

*3 Key Laboratory of Loess, Xi'an 710054, China*

*4 Key Laboratory of Western China's Mineral Resource and Geological Engineering, Ministry of Education, Xi'an 710054, China*

*5 Key Laboratory of Ecological Geology and Disaster Prevention, Ministry of Natural Resources, Laboratory of smart Earth, Beijing 100029, China*

*6 Shaanxi Geomatics Center of Ministry of Natural Resources, Xi'an 710054, China*

**Abstract:** Coseismic landslide mapping plays a crucial role in emergency response and disaster assessment. To improve landslide identification, this paper proposes a novel and enhanced model, MultiU-EGANet. The model is built upon the U-Net architecture as the baseline, with the introduction of the MultiRes module to extract feature information across multiple scales. Additionally, the Edge-Guided Attention (EGA) module is incorporated to enhance the delineation of landslide boundaries using the Laplace operator, thereby improving the segmentation accuracy at the boundaries. A composite loss function, combining Dice loss and Focal loss, is designed to further enhance the model's robustness. Using landslide data from the Jiuzhaigou area, experimental results demonstrate that the proposed model significantly improves landslide identification accuracy compared to the baseline model. Furthermore, comparative experiments conducted with landslide data from Hokkaido show that the proposed method outperforms existing models in landslide identification tasks, with F1 scores increasing by 33.31%, 5.45%, 2.31%, and 2.18%, respectively. These results validate the effectiveness of the proposed method for coseismic landslide identification.

**Keywords:** Coseismic landslide; Change detection; Multiscale; Edge-Guided

滑坡作为一种自然界广泛存在的地质现象，其本质是在外部因素（强降雨、地震等）或构造运动作用下发生的斜坡失稳向下滑落的过程(Emberson et al., 2021)。这一地质过程往往伴随着巨大的破坏力，被认为是全球分布最广、破坏最为严重的地质灾害之一(许强等, 2019; Tang et al., 2024)。其中，由地震引起的滑坡是一种常见的地震次生灾害，通常具备极大的破坏性，且造成的损失也最为严重(Keefner, 1984)。例如，2010年在青海玉树发生的 Mw6.9 地震，共诱发滑坡 2036 处，造成 2698 人死亡(Lan et al., 2013)。2023 年发生的 Mw6.2 积石山地震，诱发 3767 处滑坡，导致多条道路中断，并有大量房屋被损毁(陈博等, 2024)。因此，在地震发生后对同震滑坡进行迅速且准确的识别，对于应急救援和灾后重建具有重要意义(Lu et al., 2021)。

随着遥感技术的不断发展，遥感影像分辨率逐步提高、成像范围愈加广泛，且具有全天时、全天候的特征。因此，遥感影像在进行滑坡快速识别和定位方面得到了广泛应用(Ji et al., 2020)。基于遥感影像进行滑坡识别的方法大致可分为以下两类：基于人工的目视解译法(Zhao et al., 2017; 陈立权等, 2020)和基于计算机视觉的方法(Liu et al., 2020; Hacıfendioglu et al., 2021)。其中，基于人工的目视解译法是地质学专家根据遥感影像中呈现出来的几何、纹理等特征进行滑坡区分，尽管该方法具有较高的精度但是极度依赖专家知识，且费时费力(窦杰等, 2023)。近年来，随着计算机技术和人工智能的迅猛发展，基于计算机视觉的技术

在图像识别领域得到了广泛应用，其处理效率和识别精度均取得了显著提升。在众多计算机视觉方法中，以深度学习为核心的方法表现尤为突出，成为当前图像识别领域精度最高的技术手段之一。目前，将深度卷积神经网络(Convolutional Neural Networks, CNN)和遥感影像相结合已经逐渐成为研究热点(Jiang et al., 2022)。由于遥感图像蕴含丰富的信息，而深度神经网络在处理数据较复杂的问题时，与传统的机器学习方法相比效果性能更优。因此，基于深度学习的滑坡识别方法，相较于传统的目视解译，能够显著提高滑坡识别的速度和准确性。

Liu et al.(2020)提出了一种改进 U-Net 的卷积神经网络，并将数字高程模型 (DSM)、坡度和坡向作为附加数据，以增加样本特征参数的多样性，并对九寨沟地区进行了滑坡识别。Ghorbanzadeh et al.(2021)通过 Dempster-Shafer 模型对由 2015 年廓尔喀地震诱发的位于喜马拉雅山脉地区的滑坡进行了识别，取得了较好的识别结果。Bragagnolo et al.(2021)基于 Landsat-8 遥感影像构建出滑坡数据库，评估了 U-Net 网络在滑坡语义分割中的应用，并将该模型应用于尼泊尔地震诱发的滑坡，识别精度达到 61%。Wang et al.(2022)通过集成多种机器学习分类器，结合中国和海地地区的 Sentinel-2 和 PlanetScope 多时像图像进行滑坡识别，结果表明该方法相较于其他方法有一定的优越性。刘佳等(2022)将 U-Net 模型与 GEE 平台结合，对汶川地区进行同震滑坡识别，并比较了不同参数组合情况下 U-Net 神经网络模型的识别精度。Dai et al.(2023)基于 SegFormer 模型对泸定地区同震滑坡进行自动检测，得到了震后滑坡编目和空间分布规律，为应急救援提供了重要支持。Yang et al.(2024)提出了一种新的同震滑坡语义分割模型 ResU-SENet，并通过构建多域探测器来增强了模型的泛化能力，在帕卢地区的应用中，模型的 F1 值达到 0.6875。

在同震滑坡识别任务中，现有方法面临的主要问题包括滑坡尺寸从约 20m<sup>2</sup> 至 0.38km<sup>2</sup> 不等(Fan et al., 2018)，以及原始 CNN 模型中，单一尺寸卷积核对不规则滑坡边界信息提取不完全，从而导致边缘模糊的问题。针对这些问题，本文提出了新的改进模型—MultiU-EGANet，该模型通过对基础模型进行改进，提升了模型滑坡识别的准确性。本文主要贡献如下：(1)采用 MultiRes 块替换 U-Net 中的 3×3 卷积块，从而实现了对遥感影像的多尺度特征提取，减少模型训练过程中有效信息的丢失；(2)引入 EGA (Edge-Guided Attention) 模块以增强边界信息，从而提高滑坡边界分割的准确度，进一步提升模型的滑坡识别能力；(3)将 Dice loss 和 Focal loss 相结合，构造混合损失函数，有效解决了滑坡识别过程中滑坡像素与非滑坡像素数量不平衡的问题。

## 1、研究区概况及数据

### 1.1 研究区概况

在本研究中，使用九寨沟地区和北海道地区数据来验证所提模型性能。首先，在九寨沟地区进行实验来评估改进模型的性能；其次，在北海道地区进行对比实验，对常用分割模型与改进模型的性能进行评估，以验证改进后模型的有效性；最后，还在两个研究区进行损失函数权重选择实验，来评估不同混合损失函数的权重组合对滑坡识别精度的影响，选择最佳权重组合。

### 1.1.1 九寨沟研究区概况

2017年8月8日四川省九寨沟地区发生Mw7.0地震，此次地震的发震断层为虎牙断层西北向的延伸，震中位于北纬33.2°，东经103.82°的漳扎镇，震源深度20km(戴岚欣等, 2017)。漳扎镇隶属于四川省北部的阿坝藏族羌族自治州九寨沟县西部，地势呈南低北高，地形以山地为主。在地震发生后的36小时内发生了1700多次余震，截至2017年8月13日20时，该地震造成6人失联，25人死亡，525人受伤，176492(含游客)受灾，大量房屋与道路也受到不同程度损坏，造成经济损失约为224亿元(Fan et al., 2018)。本研究以范宣梅等人建立的滑坡编目为基础(Fan et al., 2018)，基于高分辨率遥感影像建立新的九寨沟地区滑坡编目，利用ArcGIS平台，最终解译出2017处山体滑坡，将该滑坡编目用于训练深度学习模型。研究区如图1所示，根据山体滑坡的分布特征，最终划定研究区面积为919.804 km<sup>2</sup>。

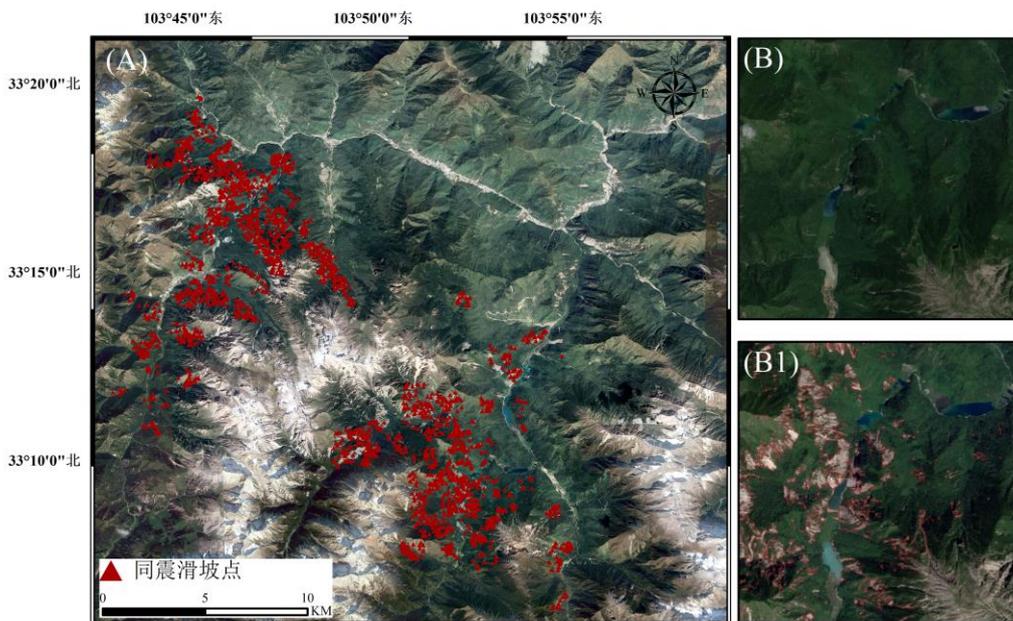


图1 九寨沟研究区(A 图为滑坡发生区, B 图为震前局部图, B1 为震后局部图)

Fig.1 Study area in Jiuzhaigou(A is the landslide occurrence area,B is the local map before the earthquake,and B1 is the local map after the earthquake.)

### 1.1.2 北海道研究区概况

当地时间2018年9月6日,日本北海道发生Mw6.7地震,震中位置为42.72°N,142.0°E,震源深度为37km。Guo 等人的反演结果表明该地震的发震断层为NNW 向东倾逆冲盲断层(走向~347.2°, 倾角~79.6°)(Guo et al., 2019)。此次地震发生在强台风“杰比”(Jebi)过境之后。台风带来的强降雨使得地表及地下水分显著增加,而该地区大约9000年前曾经历火山喷发,形成了大量的火山碎屑堆积物。这些堆积物在地震动和强降雨的共同作用下发生液化,导致液态滑坡的发生(Zhang et al., 2019)。在主震过后在受影响地区还发生多次余震,此次地震对于北海道地区乃至整个日本产生了严重的社会影响,共造成41人死亡,其中36人死于由地震引起的山体滑坡,生活设施也遭到不同程度损毁(Yamagishi and Yamazaki, 2018)。本研究在现有北海道地区滑坡编目(Chang et al., 2021)基础上进行更改,构建了新的

北海道滑坡编目。利用 ArcGIS 平台，最终解译出 7197 处山体滑坡，据此建立了该地区新的滑坡编目用于训练深度学习模型。研究区如图 2 所示，根据山体滑坡的分布特征，最终划定研究区面积为 683.86 km<sup>2</sup>。

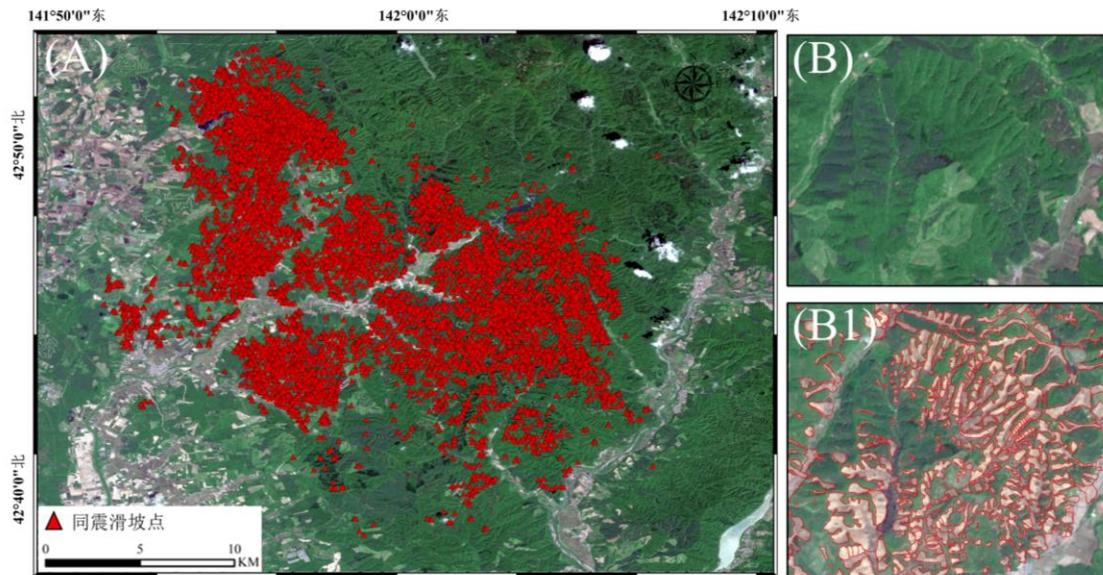


图 2 北海道研究区 (A 图为滑坡发生区, B 图为震前局部图, B1 为震后局部图)

Fig.2 Study area in Hokkaido(A is the landslide occurrence area,B is the local map before the earthquake,and B1 is the local map after the earthquake.)

## 1.2 实验数据

本研究使用了来自 Sentinel-2 卫星的光学影像, 其包含 Sentinel-2A 和 Sentinel-2B 两颗卫星, 其中 Sentinel-2A 于 2015 年 6 月 23 日发射, Sentinel-2B 发射于 2017 年 3 月 7 日。Sentinel-2 卫星携带了高分辨率多光谱成像装置, 可覆盖 13 个光谱波段, 幅宽 290 千米, 一颗卫星重访周期 10 天, 两颗卫星互补, 重访周期为 5 天, 分辨率为 10m。还使用了来自 Shuttle Radar Topography Mission(SRTM)的 DEM 数据, 分辨率为 30m。基于上述所划定的研究区范围分别选定了对应地区质量良好且云量较少的影像, 所有数据均基于 GEE(Google Earth Engine)平台免费获得。具体数据信息见表 1。

表 1 本文所使用数据集

Table1 Datasets used in this study

地区	类型	影像名称	影像时间	分辨率
九寨沟	震前 Sentinel-2	Sentinel-2	2017-07-29	10m
	震后 Sentinel-2	Sentinel-2	2017-09-07	10m
	震前 NDVI	Sentinel-2	2017-07-29	10m
	震后 NDVI	Sentinel-2	2017-09-07	10m
	坡度	SRTM DEM	2000-02-11-2000-02-21	30m
	山体阴影	SRTM DEM	2000-02-11-2000-02-21	30m

北海道	震前 Sentinel-2	Sentinel-2	2017-06-17	10m
	震后 Sentinel-2	Sentinel-2	2019-05-23	10m
	震前 NDVI	Sentinel-2	2017-06-17	10m
	震后 NDVI	Sentinel-2	2019-05-23	10m
	坡度	SRTM DEM	2000-02-11-2000-02-21	30m
	山体阴影	SRTM DEM	2000-02-11-2000-02-21	30m

NDVI 是表征地表植被覆盖和生长状态的重要指标。在植被覆盖区域，滑坡发生前后 NDVI 值会有明显差异，因此在原有 RGB 影像的基础上添加滑坡前后的 NDVI 数据，增加数据丰富性，从而提高滑坡识别准确率。坡度是滑坡发生的关键因素之一，不同坡度滑坡发生的概率也存在不同。山体阴影通过模拟光照条件突出地形的细微变化，也是在滑坡识别中广泛应用的一种地形因子。将地形因子与滑坡前后的 NDVI 值作为辅助数据与光学影像结合用于滑坡识别，能够从多维度去捕捉滑坡特征，进而增强模型性能。相比之下，DEM 数据直接反映的是地表的高程变化，与滑坡发生的关联性较弱，且包含大量冗余信息。直接使用坡度和山体阴影两种地形因子相对于直接使用 DEM 数据，不仅能更直接的提取与滑坡有关的地形特征，还能减少模型计算复杂度提，提高计算效率。因此，本研究选择将 NDVI、坡度、山体阴影数据与光学影像相结合用于滑坡识别。

上表中的震前、震后 Sentinel-2 影像指的是从相应 Sentinel-2 影像中提取出的 RGB 三波段影像。数据准备完之后需要对数据进行预处理，主要包括以下三个步骤：（1）为提高模型检测性能，因此通过 ArcGIS 软件中的重采样工具将相应研究区的坡度和山体阴影数据重采样至 10m；（2）对所有数据进行标准化处理，将其数值范围归一化至 0-255；（3）利用 ArcGIS 中的波段叠加工具，将所有数据进行融合叠加，最终构建包含 10 个波段的多源遥感数据集。

之后，利用 ArcGIS 软件中的工具包，将上述生成的多通道影像中的滑坡区域划分为  $88 \times 88$  大小用于实验。为便于进行模型训练，将两地区样本分别按 7: 3 的比例随机划分为训练集和测试集。随后，为增加训练样本的多样性并降低模型过拟合风险，采用几何变换的方式进行数据增强，主要进行了垂直翻转、水平翻转和对角线翻转操作。最终九寨沟和北海道地区均得到 1000 张样本。

## 2、实验方法

首先从 GEE 平台获取各研究区范围的光学遥感影像和 DEM 数据。然后通过一系列数据处理操作（地形因子计算、归一化、波段合成、裁剪等）生成滑坡样本数据用于模型训练。本研究以 U-Net 模型为基础模型，使用改进 MultiRes 模块替换原始卷积块并添加 EGA 模块，以提高模型精度。最后，利用改进模型对已有滑坡数据集进行训练，便于进行滑坡识别结果分析。滑坡识别具体工作流程见图 3。

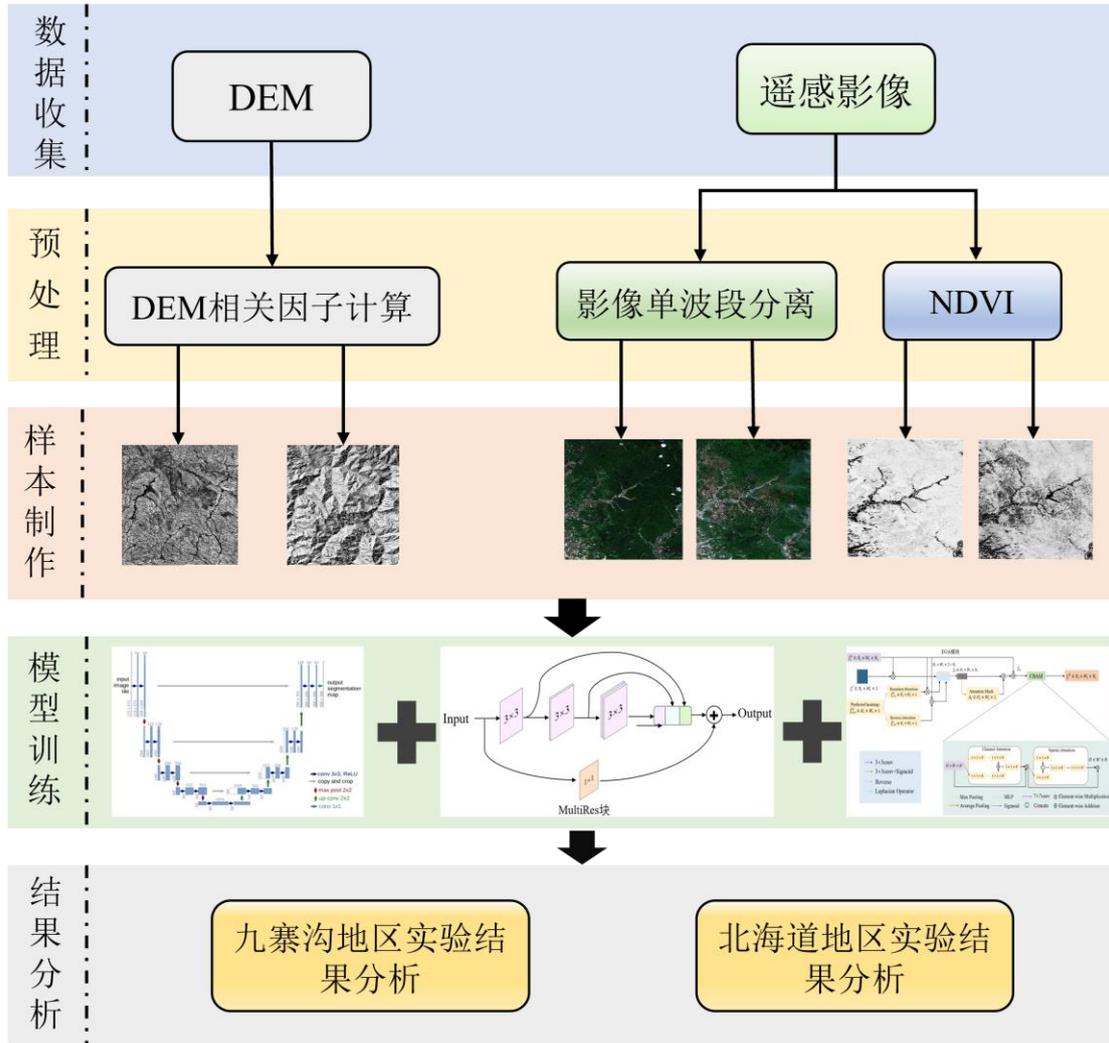


图 3 同震滑坡智能识别流程图

Fig.3 Flow chart of intelligent identification of coseismic landslides

## 2.1 模型构建

### 2.1.1 U-Net 基线模型

U-Net 模型(Ronneberger et al., 2015)最初由 Ronneberger 等人提出，用于医学图像分割任务，其架构主要由卷积层、池化层组成，具体结构见图 4。作为一种全卷积神经网络，U-Net 在使用较少训练样本的情况下能够实现高精度的分割。该模型呈现 U 型结构，包括编码器和解码器两部分。编码器部分，即 U 型结构的左侧部分，主要包括卷积层以及最大池化层，其中最大池化层用于下采样，逐步提取图像特征，并通过增加特征通道的数量和减小图像尺寸来捕捉更深层次的信息。解码器部分，即 U 型结构的右侧部分，通过反卷积操作进行上采样，将特征图恢复到原始输入图像的尺寸，并逐步生成分割结果。此外，在对应的编码器与解码器之间添加了跳跃连接（Skip Connection）结构，跳跃连接将解码器的信息与对应层中的解码器中的信息进行拼接，确保解码器能获得更高层次的信息，从而提高图像的分割精度。其中所有卷积操作均采用  $3 \times 3$  卷积，在 U 型结构最后一层，经过两次  $3 \times 3$  卷积后，

紧接着使用  $1 \times 1$  卷积将每个 64 通道的特征向量映射到本文所需的类别数。

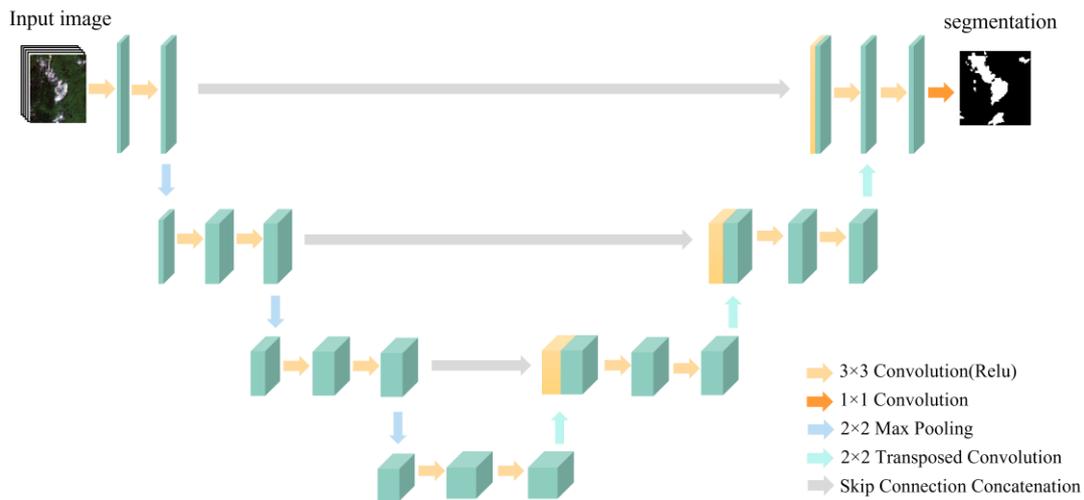


图 4 U-Net 结构图

Fig.4 Architecture of U-Net

### 2.1.2 多尺度特征提取的 MultiRes 模块

MultiRes 模块(Ibte haz 和 Rahman, 2020)是由 Ibte haz 等人提出的一种用于图像多尺度信息提取的模块 (见图 5 (b))。为增强卷积块的多尺度分析能力, MultiRes 模块通过将传统的单一  $3 \times 3$  卷积替换为多个卷积层的堆叠结构。在卷积神经网络中,卷积层堆叠可有效扩大网络的感受野,进而提升特征提取能力。在该模块中,输出由第一个  $3 \times 3$  卷积块生成的特征图传递至第二个  $3 \times 3$  卷积块,依此类推,直到传递至第三个  $3 \times 3$  卷积块,构成一个完整的卷积层 (见图 5 (a))。通过这种方式,网络能够从多个卷积块中获取不同层次信息,并对他们进行拼接,以获取不同尺度的特征信息。此外,为了避免早期层的计算需求过度传播至网络更深层, MultiRes 模块还引入了残差连接 (见图 5 (b)) (He et al., 2016)。在每个卷积层中,每个卷积块的输出通道数分别为该卷积层输出通道数的 0.167、0.333、0.5 倍,并且此模块将每个卷积层的输出通道数扩展为对应 U-Net 网络对应层数的 1.67 倍,从而进一步提高了特征提取的多样性。

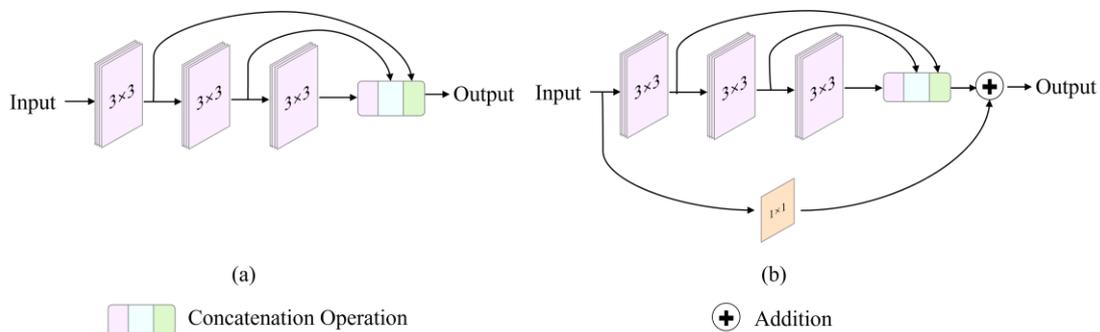


图 5 MultiRes 结构图

Fig.5 Architecture of MultiRes

### 2.1.3 边缘优化的 EGA 模块

为解决弱边界问题，Bui 等人提出边缘引导注意力 (Edge-Guided Attention, EGA) 模块，使模型能够更加聚焦于边缘相关信息(Bui et al., 2024)。EGA 模块在解码过程中集成至 U-Net 架构中，因此能够在多个尺度上运行，并针对边缘相关特征进行学习，从而丰富解码器的预测信息。EGA 模块的构成如图 6 所示。该模块需要三个输入：来自编码器的特征、经过拉普拉斯函数获得的高频特征（即边缘信息），以及由解码器生成的更高级的预测特征。EGA 模块首先将第  $i$  层编码器输出的特征  $f_i^e$  分别与计算得到的边缘信息  $f_i^l$ 、由解码器生成的高级预测特征的边界注意力信息  $f_{i+1}^b$  以及其中的反向注意力信息  $f_{i+1}^r$  相乘。随后，将得这些信息进行组合，并通过  $3 \times 3$  卷积操作得到组合特征  $f_c$ 。由于边缘信息中可能包含对滑坡识别无益的噪声，因此在第  $i$  层引入注意力掩码，记作  $A_i$ ，其目的是引导模型的注意力集中于重要区域，抑制背景噪声的干扰。第  $i$  层的注意力特征图  $f_i^a$  定义为：

$$f_i^a = \hat{f}_i^e + (f_i^c \otimes A_i) \quad (1)$$

然后将注意力特征映射  $f_i^a$  置于 CBAM (Convolutional Block Attention Module) (Woo et al., 2018) 中进行重新校准，有助于捕获边界和背景区域之间的特征相关性。CBAM 包含两个子模块：通道注意力模块和空间注意力模块。通过深度挖掘并强化通道和空间维度上的感兴趣信息，实现了对感兴趣信息的关注和不感兴趣信息的抑制。在通道注意力模块部分，上述生成的注意力特征映射  $f_i^a$  经过  $1 \times 1 \times N_i$  卷积核进行细化，从而增强模型对通道维度中关键特征的关注。在空间注意力模块部分，使用  $H_i \times W_i \times 1$  的空间卷积核对特征图进一步细化，最终输出特征图  $f_i^d$ 。

$$f_i^d = \text{CBAM}(f_i^a) \quad (2)$$

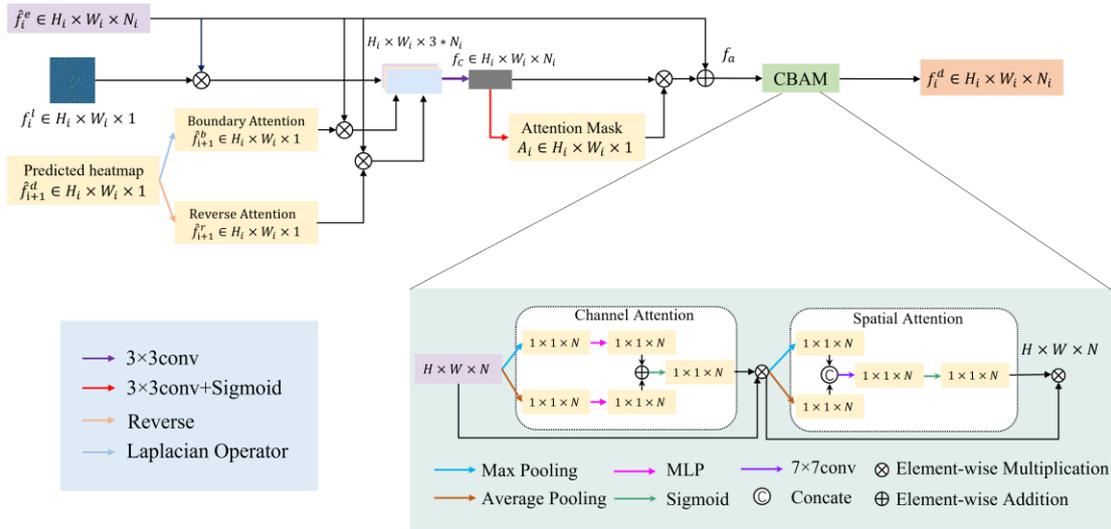


图 6 EGA 结构图

Fig.6 Architecture of EGA

### 2.1.4 MultiU-EGANet 模型

针对滑坡的多尺度问题，本文引入了 MultiRes 块，对 U-Net 模型的原始双卷积块进行

替换，并在编码器和解码器之间添加 EGA 模块，从而构建出一种新模型 MultiU-EGANet。该模型旨在提升对小尺度滑坡的识别准确率，并有效提高边界分割的准确度。

MultiU-EGANet 模型结构如图 7 所示，主要包括编码器、解码器和 EGA 模块。编码器作为特征提取器，通过下采样逐步缩小特征图尺寸，同时增加通道数，从而获取丰富的语义信息。随后，解码器通过上采样恢复特征图至原始尺寸。在该结构中，EGA 模块专注于提取和强化边缘信息，进一步优化模型的边界分割能力。在解码器中每一个 MultiRes 模块之后，都会通过  $1 \times 1$  卷积和 Sigmoid 函数生成相应尺寸的分割图，这些分割图将作为输入传递至 EGA 模块进行边缘信息提取，从而有效地建立了编码器与解码器之间的联系。

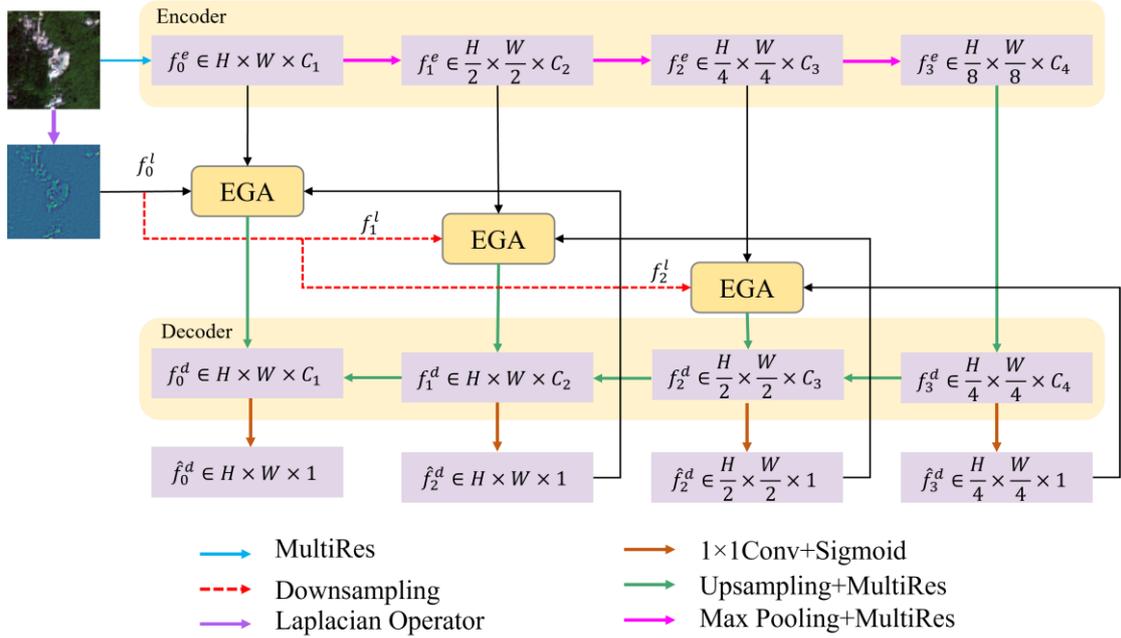


图 7 MultiU-EGANet 模型

Fig.7 MultiU-EGANet Model

## 2.2 损失函数

在滑坡识别任务中，本文采用逐像素识别的方式。在本文的数据中滑坡像素只占总像素的一小部分，这可能导致模型过于专注占比较大的非滑坡像素，从而忽略了实际需要关注的滑坡像素，进而导致模型在训练学习过程中陷入局部最小值，无法更准确的学习到滑坡的特征。为解决这一问题，本文采用了 Dice loss 损失函数(Milletari et al., 2016)来代替传统的二元交叉熵 (Binary Cross-Entropy, BCE) 损失函数。此外，为了进一步平衡滑坡像素和非滑坡像素的影响，引入了 Focal loss 损失函数(Lin et al., 2020)。Dice loss 损失函数能更精确地衡量真实标签和预测值之间的相似度，尤其在类别不平衡的情况下，展现出更优越的性能。

$$Diceloss = 1 - \frac{2 \sum_i^h \sum_j^w p_{i,j} g_{i,j} + \varepsilon}{\sum_i^h \sum_j^w p_{i,j} + g_{i,j} + \varepsilon} \quad (3)$$

其中  $h$ 、 $w$  分别表示输出预测掩码的高和宽， $i$ 、 $j$  分别表示行数和列数， $p_{i,j}$  为预测掩码，像素值为 0 或 1， $g_{i,j}$  为地面真值，像素值为 0 或 1， $\varepsilon$  为一个很小的常数。在式(2)中分母部分

表示预测掩码与地面真值的交集，分子部分表示预测掩码与地面真值的交集，当预测结果与真实结果有高度重叠时，分子也会相应更大，证明大部分像素都能被准确识别，相应的损失函数的值就会越小。这也证明该损失函数能更好的应对像素类别不平衡的问题。

Focal loss 是在交叉熵（Cross-Entropy, CE）损失函数基础上改进得到的，其目的同样是为了解决训练期间滑坡像素与背景像素之间的不平衡问题。计算公式如下：

$$Focal\ loss = -\frac{1}{H*W} \sum_{i=1}^H \sum_{j=1}^W \alpha((1-p_{i,j})^\gamma g_{i,j} \log(p_{i,j}) + p_{i,j}^\gamma (1-g_{i,j}) \log(1-p_{i,j})) \quad (4)$$

其中  $\gamma$  为调节因子，用于调节难易样本的权重， $\gamma$  参数值越大，对于易分类的样本，其损失值会越小。 $\alpha$  为平衡因子，用于平衡正负样本对损失的贡献。 $\gamma$  参数值越大，对于易分类的样本，其损失值会越小。在本实验中  $\gamma$  取值 2， $\alpha_t$  取值 0.25。将上述两个损失函数结合，最终损失函数公式为：

$$loss = a * Focal\ loss + b * Diclloss \quad (5)$$

其中 a, b 分别为 Focal loss 和 Dice loss 的权重系数，并满足 a+b=1。

### 2.3 模型评价指标

混淆矩阵（Confusion Matrix）是一个用于评估分类模型性能的可视化工具。其通过对模型预测结果和真实标签的比较来对模型性能进行分析，呈现一个二维表格的形式，如表 2 所示：

表 2 混淆矩阵

真值 \ 预测	滑坡	非滑坡
滑坡	TP	FP
非滑坡	FN	TN

其中 TP(True Positive)指实际为滑坡预测也为滑坡的像素数量，FP(False Positive)指实际为非滑坡但被预测为滑坡的像素数量，FN(False Negative)指实际为滑坡但被预测为非滑坡的像素数量，TN(True Positive)指实际为非滑坡预测也为非滑坡的像素数量。基于上述四个值，计算了 4 种常用的评价指标对模型性能进行评估(Li et al., 2024)，即 Precision、Recall、Intersection over Union(IoU)、F1-score。分别定义为：

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

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

$$IoU = \frac{TP}{TP + FP + FN} \quad (8)$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (9)$$

### 3、 实验结果

#### 3.1 实验设置

在本项研究中，实验配置为：处理器 Intel(R) Core(TM) i5-14600KF，运行内存 64GB，显卡 NVIDIA GeForce RTX 4090，深度学习框架为 PyTorch3.8，使用的编程语言为 Python。使用 Adam 优化器，初始学习率为 0.005，并设置了学习率降低策略，在验证时损失值连续 5 个 epoch 不改变或上升则按一定比例降低学习率，batch-size 为 64，num\_workers 为 2。

#### 3.2 滑坡识别结果

本研究对比分析了改进后的模型与基线模型在九寨沟地区的识别结果，如表 3 所示。分析表明，添加了 EGA 模块和 MultiRes 模块的改进模型性能优于基线模型，F1 值为 0.8334，相较于基线模型提高了 2.31%，recall 值提高了 1.03%，precision 值提高了 3.37%，IoU 值提高了 3.34%。这些显著的性能提升验证了所提出的模型改进策略在滑坡识别任务中的有效性。

表 3 九寨沟区域识别结果

Table3 Identification results in Jiuzhaigou

模型	precision	recall	F1_score	IoU
U-Net	0.7717	0.8530	0.8103	0.6801
MultiU-EGANet	<b>0.8054</b>	<b>0.8633</b>	<b>0.8334</b>	<b>0.7135</b>

图 8 为初始 U-Net 模型和改进模型在九寨沟地区的滑坡识别结果。通过与地表真值对比分析，初始 U-Net 模型能够较好地描绘滑坡区域，但在某些区域的滑坡边界分割存在不准确的现象，且存在漏检和误检现象。相较于 U-Net 模型，MultiU-EGANet 模型能更准确的学习到滑坡细节识别不同尺度的滑坡，且边界分割更准确。如图 8 中第一行所示，改进模型在细节部分识别上更为准确，且边界分割也更为精准；在第二行中，虽然改进模型跟 U-Net 模型一样会存在一定程度的误检，但在滑坡细节分割和误检率方面，改进模型表现出更优的效果；在第三、第四行中，改进模型相较于 U-Net 表现出更高的准确性，例如红框所圈画部分，改进模型能够更准确的识别滑坡。此外，在第三行中，红框圈画范围外有部分小尺寸滑坡，改进模型准确识别到了这类滑坡的位置，表明改进模型有效减少了漏检率。这一结果与前述定量分析中 recall 值有提升相一致。

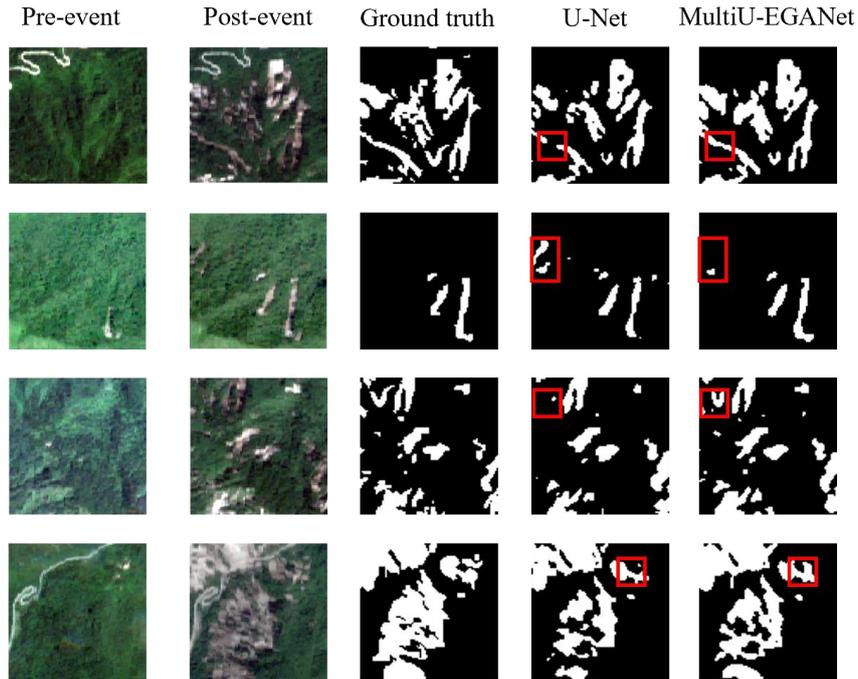


图 8 九寨沟地区滑坡识别结果

Fig.8 Landslide identification results in Jiuzhaigou

### 3.3 模型对比实验

为更全面地验证本文所提出改进模型的有效性，本文以北海道为研究区域，将改进模型与常用的经典分割网络如 FCN(Shelhamer et al., 2017)、SegNet(Badrinarayanan et al., 2017)等进行对比实验，以表明改进模型在同震滑坡识别结果上的先进性。全卷积网络(Fully Convolutional Networks,FCN)，其使用卷积层替换了原始卷积神经网络中的全连接层，因此可以适应任意尺寸的输入，并生成相应尺度的像素级预测标签(Shelhamer et al., 2017)。与 FCN 不同 SegNet 是编码器-解码器架构，其是一个端到端的深度学习语义分割模型，其上采样直接用编码网络中记载的 MaxPool 坐标，将每个窗口的最大值放到窗口上相应位置，其余位置全部设为 0，在这一段不进行学习，没有参数产生，有效降低内存需求(Badrinarayanan et al., 2017)。除此之外还有 U-Net 模型的变体 Res-UNet(Zhang et al., 2018)，ResU-SENet(Yang et al., 2024)。Res-UNet 结合了 U-Net 的编码器-解码器结构与残差网络的优势，既能有效提取多尺度特征，又能够缓解深层网络中的梯度消失问题，从而提升模型的训练效率和精度(Zhang et al., 2018)。ResU-SENet 在 Res-UNet 基础上引入 SE 模块对特征通道进行自适应加权优化，结合 U-Net 的多尺度特征提取与残差网络的高效训练能力，使得模型在处理复杂任务时具备更强的特征选择能力和更高的识别精度(Yang et al., 2024)。

与九寨沟地区不同，北海道地区植被茂密，滑坡分布密集，且多为小尺寸滑坡。表 4 展示了北海道地区对比实验的定量分析结果。通过对比发现，MultiU-EGANet 的各项评价指标均取得了最优结果，precision 达到 0.8787，recall 为 0.8945，F1\_score 为 0.8865，IoU 为 0.7960。虽然相较于 Res-UNet 和 ResU-SENet 模型，改进模型的数量有所增加，但各项评价指标均有所提升，这证明增加的可学习参数有效地提高了模型性能，有效平衡了分割精度和网络

复杂性。

表 4 北海道地区对比试验结果

Table4 Results of comparative tests in Hokkaido

模型	precision	recall	F1_score	IoU	Params
FCN	0.5444	0.7552	0.6327	0.4629	7916316
Segnet	0.8510	0.8527	0.8518	0.7415	7369441
Res-UNet	0.8678	0.8762	0.8720	0.7729	3269217
ResU-SENet	0.8547	0.8933	0.8736	0.7742	3271905
MultiU-EGANet	<b>0.8787</b>	<b>0.8945</b>	<b>0.8865</b>	<b>0.7960</b>	<b>4718235</b>

除上述定量分析外本文还进行了定性分析，来更好的展示模型分割效果。本研究选取了四个示例来进行分析，识别结果如图 9 所示。在选取的四个示例中，前两个示例包含许多小尺度滑坡，且第一个示例中滑坡分布密集，第三个和第四个示例中多为大尺度滑坡。通过将各种模型的分割结果与地表真值对比发现均存在漏检现象，但是本文所提出的方法的漏检相对所对比的四种方法来说较少，这与表 4 中本文所提方法的 recall 值最高相对应。FCN 模型只能识别大尺寸滑坡或识别出滑坡的密集区域不能很好的分割出小尺寸滑坡，这也与表 4 中其各项评价指标最低相对应。Segnet 模型相较于 FCN 模型能分割出不同面积的滑坡，但是漏检较多，且分割出的滑坡边界模糊、不准确。Res-UNet 模型相较于前两个模型漏检率有了一定程度的减少，对小尺度滑坡的敏感度有一定程度提高，但其对于有些区域分割不充分，将滑坡区域识别为背景。ResU-SENet 通过添加通道注意力机制提高了整体的识别精度，但是对于边界的分割仍不准确，部分滑坡边界缺失。MultiU-EGANet 模型不仅对不同尺寸滑坡能很好的识别而且对于边界的分割也更准确，其分割效果明显优于其他分割模型。

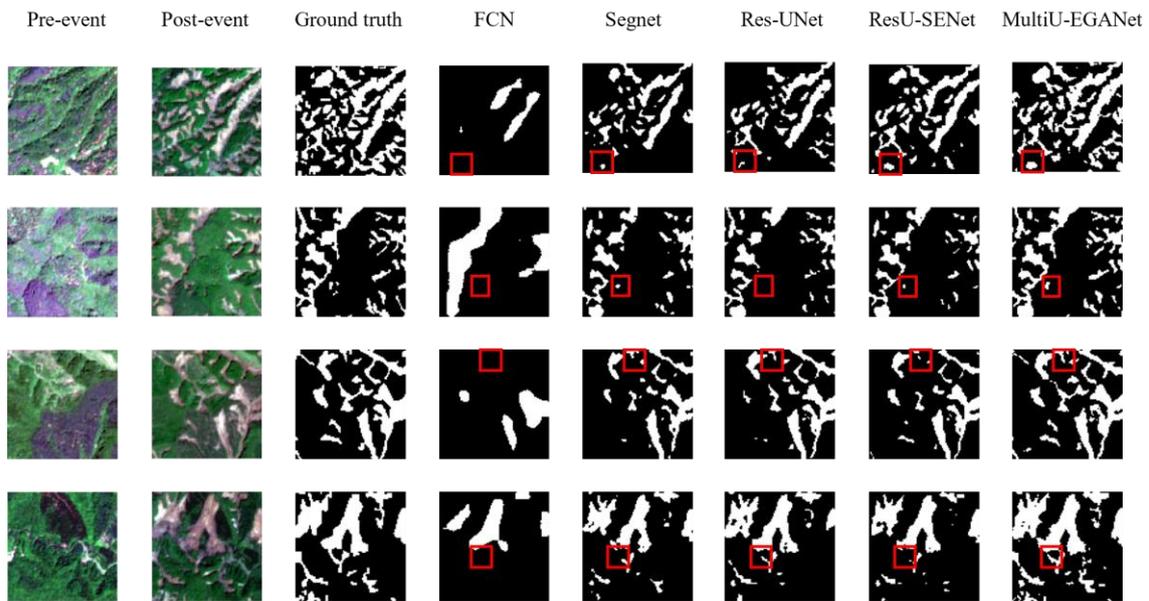


图 9 北海道地区滑坡识别结果

Fig.9 Landslide identification results in Hokkaido

## 4、讨论

### 4.1 各模块对模型性能的影响

本研究中提出了一种滑坡识别的新框架，是基于 U-Net 结构的改变。该框架改变了 U-Net 的原始卷积块，并添加了边缘引导注意力模块，提升了网络的特征提取能力以及图形分割精度。为了更好的体现各模块的具体贡献，进行了一定的实验，在实验中主要对比了四种不同的架构。分别是基础的 U-Net 架构、将 U-Net 中卷积块替换为 MultiRes 块的架构、在 U-Net 中间的跳跃连接处添加 EGA 块的架构和将 U-Net 中卷积块替换为 MultiRes 块并在跳跃连接处添加 EGA 块的架构。实验结果如表 5 所示。经过对比发现本文所提出的方法效果最好，F1 得分为 0.8334，相较于原始 U-Net 模型提高了 2.31%，recall 值提高了 1.03%，precision 值提高了 3.37%，IoU 值提高了 3.34%。而且单独使用 MultiRes 模块和单独使用 EGA 模块相较于原始模型结果都有一定提高。

表 5 九寨沟区域实验结果

Table 5 Experimental results in Jiuzhaigou

模型	precision	recall	F1_score	IoU
U-Net	0.7717	0.8530	0.8103	0.6801
MultiU-Net	0.7767	0.8628	0.8175	0.6907
U-EGANet	0.7837	0.8548	0.8177	0.6875
MultiU-EGANet	<b>0.8054</b>	<b>0.8633</b>	<b>0.8334</b>	<b>0.7135</b>

除定量分析外还进行了定性分析，如图 10，展示了在九寨沟地区的部分分割结果。通过与地表真值对比，初始 U-Net 模型可以较好的识别滑坡区域，但在某些区域，不能准确的分割出滑坡边界，并出现了漏检和误检现象。通过观察图 10 可以发现，相较于 U-Net 模型，添加了 MultiRes 模块的模型相较于基础模型，识别准确度有一定程度提高，尤其是一些位于边缘部位的小型滑坡，但也存在对边界识别不准确的问题，添加了 EGA 模块的模型在边界优化方面相较于基础模型有一定改进。由结果可知，所提出的方法无论是在边界分割还是对于不同尺度的滑坡识别方面均优于初始模型。这是因为 MultiRes 模块提高了模型对不同尺度滑坡的关注度，EGA 模块提高了对滑坡边界的关注度，进而整体提高滑坡识别精度。

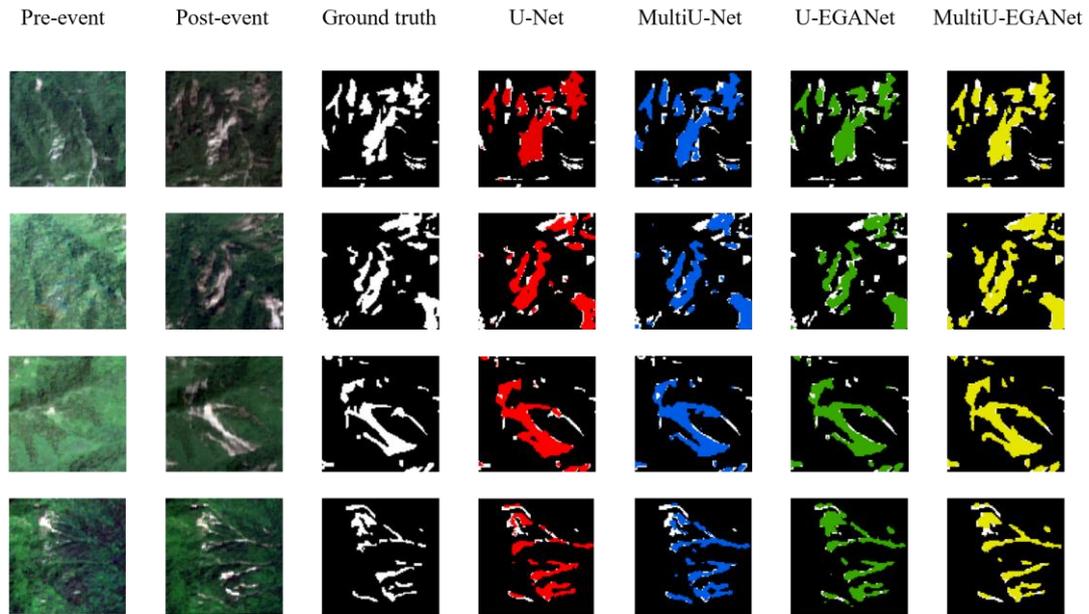


图 10 九寨沟地区滑坡分割结果

Fig.10 Segmentation results of landslides in Jiuzhaigou

#### 4.2 滑坡尺度划分与模型改进效果分析

滑坡具有规模范围大、尺度不一、形状多样等特征，传统的检测模型通常难以有效捕捉这些多尺度特征。本研究针对九寨沟地区滑坡尺寸进行了统计与分析，并根据尺寸大小将滑坡划分为三类：小尺度滑坡（ $S < 10^4 \text{m}^2$ ）、中尺度滑坡（ $10^4 \text{m}^2 \leq S < 10^5 \text{m}^2$ ）、大尺度滑坡（ $S > 10^5 \text{m}^2$ ）。在本研究中，改进前后模型在不同尺度滑坡识别任务中的 F1 值进行了统计，具体结果如图 11 所示。从结果可见，改进后的模型在各尺度滑坡识别任务中均表现出较高的 F1 值。在不同尺度滑坡的识别中，大尺度滑坡识别效果优于小尺度滑坡，改进模型的性能在小尺度滑坡中表现更好。该结果可归因于以下因素：首先，小尺度滑坡通常位于复杂的地理背景中，容易受到周围地物和地形特征的干扰，这增加了滑坡识别的难度，进而影响了模型的识别精度。相比之下，大尺度滑坡由于具有明显的边界和显著的地形变化，能够为模型提供更为清晰的地理信息，从而提高了识别效果。其次，本研究采用的 10 米分辨率数据在处理小尺度滑坡时存在一定局限性，因为小尺度滑坡的尺寸较小，导致在该分辨率下无法提供足够的细节信息，进一步增加了滑坡识别的难度。为克服这一问题，本文提出的改进模型通过 MultiRes 模块在多个尺度上进行特征提取，并对提取的多尺度特征进行融合，从而使模型能够有效整合不同尺度的信息，增强了对滑坡细节的关注，并显著提升了识别的准确性。因此，改进后的模型在处理多尺度滑坡识别任务时，能够有效应对上述挑战，尤其在小尺度滑坡的识别任务中表现出更加显著的优势。

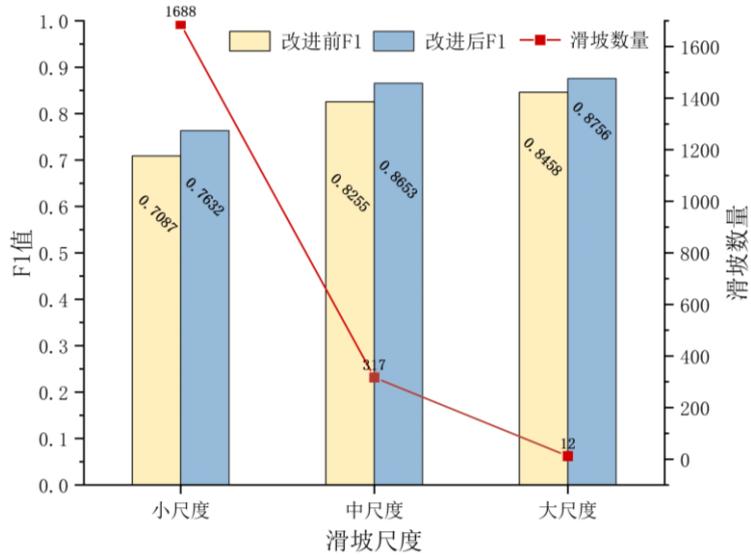


图 11 滑坡大小统计及各尺度 F1 值

Fig.11 Statistical of landslide size and F1 value of each scale.

为更好地展示模型的分割效果，还进行了定性分析，如图 12 所示。第一行红框所圈部分为小尺度滑坡，可以观察到改进前存在大量误检，而改进后模型误检率明显降低。第二行红框所圈部分为中尺度滑坡，改进前模型识别准确率略低，改进后模型相对改进前模型识别结果有一定程度的提升。第三行显示为大尺度滑坡，对于大尺度滑坡，改进后模型在识别完整度上明显优于改进前模型，能够更全面的识别滑坡区域。

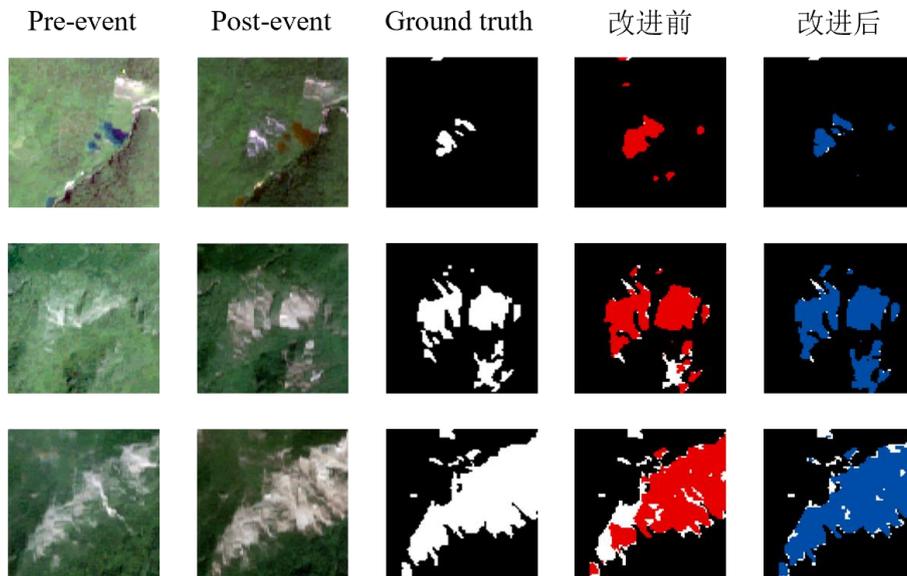


图 12 不同尺寸识别结果

Fig.12 Recognition results for different sizes

#### 4.3 损失函数权重选择

为了确定损失函数中不同  $a$ 、 $b$  取值对模型性能的影响，本文设置了一系列实验即将  $a$  从 1 每次减少 0.1 直至 0，相应的  $b$  从 0 每次增加 0.1 直至 1，来选取能更好的发挥模型性

能的 a、b 值。因为九寨沟和北海道地区的差异，为了更好地选择出适合每个地区的损失函数，在两个地区均进行了基于损失函数的权重选择实验。具体结果见表 6、表 7。

表 6 九寨沟损失函数权重选择

Table6 Weight selection of loss function in Jiuzhaigou

a	b	precision	recall	F1_score	IoU
1	0	0.7871	0.8745	0.8285	0.7048
0.9	0.1	0.7905	0.8659	0.8265	0.7016
0.8	0.2	0.7837	0.8590	0.8196	0.6903
0.7	0.3	<b>0.8054</b>	0.8633	<b>0.8334</b>	<b>0.7135</b>
0.6	0.4	0.7928	0.8519	0.8213	0.6945
0.5	0.5	0.7790	0.8903	0.8309	0.7103
0.4	0.6	0.7674	<b>0.8926</b>	0.8253	0.7019
0.3	0.7	0.7834	0.8517	0.8161	0.6853
0.2	0.8	0.7846	0.8642	0.8225	0.6975
0.1	0.9	0.7605	0.8616	0.8079	0.6737
0	1	0.8032	0.8208	0.8119	0.6800

从表 6 中可以看出在九寨沟地区相较于只使用 Dice loss 的情况，当 Dice loss 权重为 0.7，Focal loss 权重为 0.3 时，F1 值提高 0.49%，precision 值提高 1.83%，IoU 值提高了 0.87%。

表 7 北海道损失函数权重选择

Table7 Weight selection of loss function in Hokkaido

a	b	precision	recall	F1_score	IoU
1	0	0.8631	0.9083	0.8851	0.7937
0.9	0.1	<b>0.8787</b>	0.8945	<b>0.8865</b>	<b>0.7960</b>
0.8	0.2	0.8576	0.9054	0.8809	0.7866
0.7	0.3	0.8668	0.9022	0.8842	0.7920
0.6	0.4	0.8590	0.9035	0.8807	0.7865
0.5	0.5	0.8601	0.9092	0.8840	0.7918
0.4	0.6	0.8552	0.9088	0.8812	0.7872
0.3	0.7	0.8593	<b>0.9150</b>	0.8863	0.7956
0.2	0.8	0.8643	0.9004	0.8820	0.7888

0.1	0.9	0.8729	0.8951	0.8839	0.7916
0	1	0.8785	0.8815	0.8800	0.7857

在北海道地区通过对比表 7 中各项指标可知，相较于只使用 Dice loss 和只使用 Focal loss 的情况下，当 Dice loss 权重为 0.9，Focal loss 权重为 0.1 时，改进后模型取得最好结果

图 13 给出了九寨沟地区和北海道地区只使用 Dice loss 和使用混合损失函数的训练损失曲线，其中字母 B 代表北海道地区，字母 J 代表九寨沟地区。可以看出在训练开始时损失曲线明显下降。由九寨沟地区损失变化曲线可知使用混合损失函数的曲线收敛较快。通过观察黑色曲线即北海道地区损失变化曲线，虚线部分在大约 50epochs 后即开始收敛，收敛至 0.1，而黑色曲线在大约 70epochs 后才开始收敛。经过上述对比表明混合损失函数能有效提高模型收敛速度。

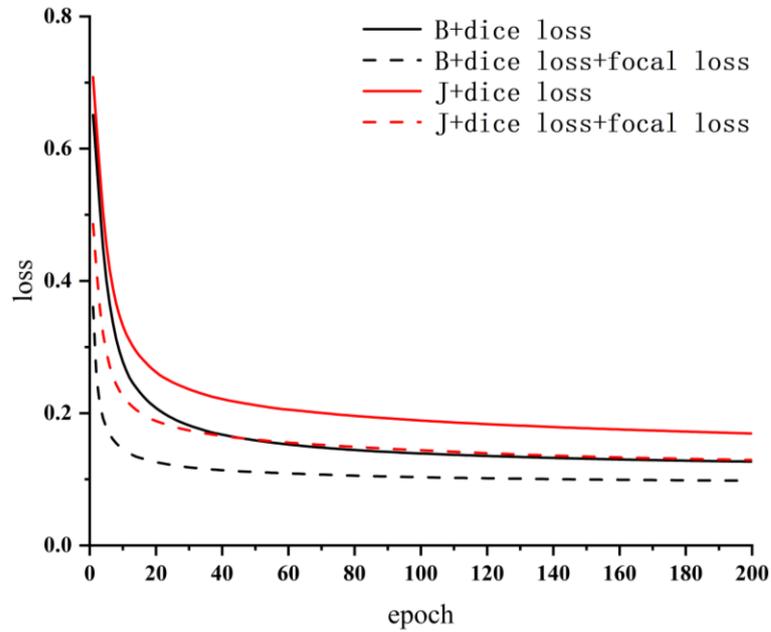


图 13 不同损失函数影响

Fig.13 The effects of different loss function

#### 4.4 模型泛化性能

为了测试模型的泛化性能，将上述北海道、九寨沟实验中训练的模型用于预测未知区域—帕卢的地震滑坡。帕卢位于印度尼西亚中部的苏拉威西岛，在 2018 年 9 月 28 日发生 Mw7.5 大型地震。此次地震对帕卢地区造成严重破坏，造成多人伤亡，大量建筑物倒塌，大量基础设施被损坏，对当地生活及经济产生极大影响。

从表 8 可以看出，无论是以九寨沟为源域的模型还是以北海道为源域的模型，改进模型在帕卢地区的滑坡识别结果均优于基础模型，且以北海道地区为源域的模型的滑坡识别结果优于以九寨沟地区为源域的模型的识别结果。基于北海道地区的 MultiU-EGANet 在帕卢地区的滑坡识别 F1 值为 0.6813。值得注意的是，北海道地区与帕卢地区的震中都位于沿海区域，且两地滑坡性质相似，都是因土壤液化引起的山体滑坡，与背景区别较为明显，二者具

有相似的地理环境与触发机制。为此，本文选取了广泛使用的分布差异度量方法—最大均值差异（Maximum Mean Discrepancy, MMD），来衡量源域和目标域之间的分布差异(Borgwardt et al., 2006)。

MMD 的核心思想是通过比较两个不同分布在高维特征空间（再生核希尔伯特空间，RKHS）中的均值嵌入来量化分布差异。假设有两个来自不同分布的样本集  $X=\{x_1, x_2, \dots, x_n\}$  和  $Y=\{y_1, y_2, \dots, y_m\}$ ，MMD 计算公式为：

$$MMD = \left\| \frac{1}{n} \sum_{i=1}^n f(x_i) - \frac{1}{m} \sum_{j=1}^m f(y_j) \right\|_H \quad (10)$$

其中，H 为 RKHS， $f(\cdot)$  为映射函数，将样本  $x_i$  和  $y_j$  映射到 RKHS。本文以九寨沟和北海道作为源域，帕卢作为目标域，每个地区总体数据作为输入值，进行了 MMD 值计算。其中九寨沟与帕卢之间的 MMD 值为 2.4164，北海道与帕卢之间的 MMD 值为 1.2408。北海道与帕卢之间的 MMD 值明显低于九寨沟与帕卢之间的 MMD 值，MMD 值越小，表明两者分布越为相似，这意味着帕卢与北海道的空间分布更为接近，这恰好解释了北海道地区的模型在帕卢的滑坡识别结果优于九寨沟地区的模型在帕卢的滑坡识别结果。同时证明，MMD 值越小，源域与目标域分布越为相似，这种情况下源域模型在目标域具有较好的泛化性能。

与同类工作相比，实验得到的 MMD 值与模型泛化性能呈负相关这一结论与 Yang et al.(2024)一致，并且由于 MultiRes 模块和 EGA 模块的引入，本文所提 MultiU-EGANet 的 F1 值较 SE 注意力机制与 ResU-Net 网络相结合的 ResU-SENet 的 F1 值提升了 0.433。

表 8 不同源域的模型在帕卢地区的滑坡识别结果

Table8 Landslide identification results of models with different source domains in Palu

源域	泛化域	模型	precision	recall	F1_score	IoU
九寨沟		U-Net	0.1061	0.0205	0.0320	0.0167
九寨沟	帕卢	MultiU-EGANet	0.1594	0.1608	0.1529	0.0839
北海道		U-Net	<b>0.9660</b>	0.2464	0.3761	0.2417
北海道		MultiU-EGANet	0.9312	<b>0.5432</b>	<b>0.6813</b>	<b>0.5222</b>

#### 4.5 不足与展望

尽管改进模型在所选研究区内取得了较为良好的滑坡识别结果，但仍存在一定的局限性待后续改进：

（1）本文所选研究区的滑坡大部分位于植被茂密区，滑坡发生后地表特征变化较为明显。然而，对于存在裸地的区域，模型易发生误识别。因此未来可通过优化模型结构与特征提取方法，以进一步提升裸地区域滑坡识别的准确率。

（2）改进后的模型虽然在识别精度方面表现优异，但其训练参数量较大且内存占用较高，这在一定程度上限制了模型的实际部署与应用。针对这一问题，未来可尝试采用网络剪枝技术，在保证模型识别准确率不变的前提下，显著减少模型参数量，从而提高模型的计算

效率和实用性。

## 5、结论

本研究以 Sentinel-2 影像和 DEM 数据为主要数据源，分别选取九寨沟、北海道地区作为研究区域，构建了相应数据集，并提出了一种改进的滑坡识别模型 MultiU-EGANet。通过模型实验分析，主要得出如下结论：（1）在九寨沟地区，改进的模型对同震滑坡的识别结果达到了 0.8054 的准确率、0.8633 的召回率、0.8334 的 F1 值和 0.7135 的 IoU 值，相较于初始模型分别提高 2.31%、1.03%、3.37%、3.34%。（2）在北海道地区，与经典分割模型的对比实验结果表明，改进模型能够较为准确地分割同震滑坡的边界，并有效检测同震滑坡的位置，从而提升了识别的准确性和可靠性。（3）通过消融实验证明了所添加模块的有效性，添加 MultiRes 模块后，滑坡识别准确率提高了 0.5%，F1 值提高了 0.72%，添加 EGA 模块后，滑坡识别准确率提高了 1.2%，F1 值提高了 0.74%。（4）通过两个地区的损失函数权重选择实验可以发现，Dice loss 和 Focal loss 按一定比例分配权重混合使用时，与只使用 Dice loss 相比，不仅能提高滑坡识别准确率，且模型收敛速度加快。

## References

- Badrinarayanan, V., Kendall, A., Cipolla, R., 2017. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12):2481–2495. DOI:10.1109/TPAMI.2016.2644615.
- Borgwardt, K.M., Gretton, A., Rasch, M.J., et al., 2006. Integrating structured biological data by Kernel Maximum Mean Discrepancy. *Bioinformatics*, 22(14):e49–e57. DOI:10.1093/bioinformatics/btl242.
- Bragagnolo, L., Rezende, L.R., Da Silva, R.V., et al., 2021. Convolutional neural networks applied to semantic segmentation of landslide scars. *Catena*, 201:105189. DOI: 10.1016/j.catena.2021.105189.
- Bui, N.-T., Hoang, D.-H., Nguyen, Q.-T., et al., 2024. MEGANet: Multi-Scale Edge-Guided Attention Network for Weak Boundary Polyp Segmentation, in: 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), Presented at the 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), pp. 7970–7979.
- Chang, M., Zhou, Y., Zhou, C., et al., 2021. Coseismic landslides induced by the 2018 Mw6.6 Iburi, Japan, Earthquake: spatial distribution, key factors weight, and susceptibility regionalization. *Landslides*, 18(2):755–772. DOI:10.1007/s10346-020-01522-3.
- Chen, B., Song, C., Chen, Y., et al., 2025. Emergency Identification and Influencing Factor Analysis of Coseismic Landslides and Building Damages Induced by the 2023 Ms 6.2 Jishishan (Gansu, China) Earthquake. *Geomatics and Information Science of Wuhan University*, 50(2):322-332(in Chinese with English abstract).
- Chen, L.Q., Zhao, C.Y., Ren, C.F., et al., 2020. Monitoring the Jianshanying Landslide in a Karst Mountainous Area of Guizhou by Optical Remote Sensing. *Carsologica Sinica*, 39(4): 518-523(in Chinese).
- Dai, L.X., Fan, X.M., Wang, X., et al., 2023. Coseismic landslides triggered by the 2022 Luding Ms6.8 earthquake, China. *Landslides*, 20(6):1277–1292. DOI:10.1007/s10346-023-02061-3.
- Dai, L.X., Xu, Q., Fan, X.M., et al., 2017. A Preliminary Study on Spatial Distribution Patterns of Landslides Triggered by JiuZhaigou Earthquake in SiChuan on August 8th, 2017 and Their Susceptibility Assessment. *Journal of Engineering Geology*, 25(4): 1151-1164(in Chinese with English abstract).

- Dou J., Xiang Z., Xu Q., et al., 2023. Application and Development Trend of Machine Learning in Landslide Intelligent Disaster Prevention and Mitigation. *Earth Science*, 48(5): 1657-1674(in Chinese with English abstract).
- Emberson, R., Kirschbaum, D., Stanley, T., 2021. Global connections between El Nino and landslide impacts. *Nat. Commun.*, 12(1):2262. DOI:10.1038/s41467-021-22398-4.
- Fan, X.M., Scaringi, G., Xu, Q., et al., 2018. Coseismic landslides triggered by the 8th August 2017 Ms 7.0 Jiuzhaigou earthquake (Sichuan, China): factors controlling their spatial distribution and implications for the seismogenic blind fault identification. *Landslides*, 15(5):967–983. DOI:10.1007/s10346-018-0960-x.
- Ghorbanzadeh, O., Meena, S.R., Shahabi Sorman Abadi, H., et al., 2021. Landslide Mapping Using Two Main Deep-Learning Convolution Neural Network Streams Combined by the Dempster–Shafer Model. *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, 14:452–463. DOI:10.1109/JSTARS.2020.3043836.
- Guo, Z.L., Wen, Y.M., Xu, G.Y., et al., 2019. Fault Slip Model of the 2018 Mw 6.6 Hokkaido Eastern Iburi, Japan, Earthquake Estimated from Satellite Radar and GPS Measurements. *Remote Sensing*, 11(14):1667.
- Guzzetti, F., Mondini, A., C., Cardinali, M., et al., 2012. Landslide Inventory Maps: New Tools for an Old Problem. *Earth-Science Reviews*, 112(1): 42-66. DOI:10.3390/rs11141667.
- Hacrefendioğlu, K., Demir, G., Başağa, H.B., 2021. Landslide detection using visualization techniques for deep convolutional neural network models. *Nat Hazards*, 109(1):329–350. DOI:10.1007/s11069-021-04838-y.
- He, K.M., Zhang, X.Y., Ren, S.Q., et al., 2016. Identity Mappings in Deep Residual Networks, in: B. Leibe, J. Matas, N. Sebe, et al. (Eds.), *COMPUTER VISION - ECCV 2016, PT IV, Lecture Notes in Computer Science*, Presented at the 14th European Conference on Computer Vision (ECCV), Springer International Publishing Ag, Cham, pp. 630–645.
- Ibtehaz, N., Rahman, M.S., 2020. MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*, 121:74–87. DOI:10.1016/j.neunet.2019.08.025.
- Ji, S.P., Yu, D.W., Shen, C.Y., et al., 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, H.W., Peng, M., Zhong, Y.J., et al., 2022. A Survey on Deep Learning-Based Change Detection from High-Resolution Remote Sensing Images. *Remote Sensing*, 14(7):1552. DOI:10.3390/rs14071552.
- Keefer, D.K., 1984. Landslides caused by earthquakes. *Geological Society of America Bulletin*, (95):406–421.
- Lan, H.X., Li, L.P., Zhang, Y.S., et al., 2013. Risk assessment of debris flow in Yushu seismic area in China: a perspective for the reconstruction. *Natural Hazards and Earth System Sciences*, 13(11):2957–2968. DOI:10.5194/nhess-13-2957-2013.
- Li, Y.L., Ding, M.T., Zhang, Q., et al., 2024. Old Landslide Detection Using Optical Remote Sensing Images Based on Improved YOLOv8. *Applied Sciences*, 14(3):1100. DOI:10.3390/app14031100.
- Lin, T.-Y., Goyal, P., Girshick, R., et al., 2020. Focal Loss for Dense Object Detection. *IEEE Trans. Pattern Anal. Mach. Intell.*, 42(2):318–327. DOI:10.1109/TPAMI.2018.2858826.
- Liu, J., Wu, Y. M., Gao, X., et al., 2022. Image Recognition of Co-seismic Landslide Based on GEE and U-net Neural Network. *Journal of Geo-information Science*, 24(7):1275-1285(in Chinese with English abstract).
- Liu, P., Wei, Y.M., Wang, Q., et al., 2020. Research on Post-Earthquake Landslide Extraction Algorithm Based on Improved U-Net Model. *Remote Sens.*, 12(5):894. DOI:10.3390/rs12050894.
- Lu, P., Shi, W.Y., Wang, Q.M., et al., 2021. Co-seismic landslide mapping using Sentinel-2 10-m fused NIR narrow, red-edge, and SWIR bands. *Landslides*, 18(6):2017–2037. DOI:10.1007/s10346-021-01636-2.
- Milletari, F., Navab, N., Ahmadi, S.-A., 2016. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation, in: *Proceedings of 2016 Fourth International Conference on 3D Vision (3DV)*,

- International Conference on 3D Vision, Presented at the 4th IEEE International Conference on 3D Vision (3DV), IEEE, New York, pp. 565–571.
- Mondini, A.C., Guzzetti, F., Reichenbach, P., et al., 2011. Semi-automatic recognition and mapping of rainfall induced shallow landslides using optical satellite images. *Remote Sensing of Environment*, 115(7):1743–1757. DOI:10.1016/j.rse.2011.03.006.
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation, in: N. Navab, J. Hornegger, W.M. Wells, et al. (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Springer International Publishing, Cham, pp. 234–241.
- Shelhamer, E., Long, J., Darrell, T., 2017. Fully Convolutional Networks for Semantic Segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.*, 39(4):640–651. DOI:10.1109/TPAMI.2016.2572683.
- Tang, X., Wang, L., Wang, H., et al., 2024. Predicted Climate Change will Increase Landslide Risk in Hanjiang River Basin, China. *J. Earth Sci.*, 35(4):1334–1354. DOI:10.1007/s12583-021-1511-2.
- Wang, X., Fan, X.M., Xu, Q., et al., 2022. Change detection-based co-seismic landslide mapping through extended morphological profiles and ensemble strategy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 187:225–239. DOI:10.1016/j.isprsjprs.2022.03.011.
- Woo, S., Park, J., Lee, J.-Y., et al., 2018. CBAM: Convolutional Block Attention Module, in: V. Ferrari, M. Hebert, C. Sminchisescu, et al. (Eds.), *Computer Vision - ECCV 2018, PT VII*, Lecture Notes in Computer Science, Presented at the 15th European Conference on Computer Vision (ECCV), Springer International Publishing Ag, Cham, pp. 3–19.
- Xu, Q., Dong, X.J., Li, W.L., 2019. Integrated Space-Air-Ground Early Detection, Monitoring and Warning System for Potential Catastrophic Geohazards. *Geomatics and Information Science of Wuhan University*, 44(7): 957-966(in Chinese).
- Yamagishi, H., Yamazaki, F., 2018. Landslides by the 2018 Hokkaido Ibur-Tobu Earthquake on September 6. *Landslides*, 15(12):2521–2524. DOI:10.1007/s10346-018-1092-z.
- Yang, J., Ding, M.T., Huang, W.B., et al., 2024. A Generalized Deep Learning-Based Method for Rapid Co-Seismic Landslide Mapping. *IEEE J. Sel. Top. Appl. Earth Observ. Remote Sens.*, 17:16970–16983. DOI:10.1109/JSTARS.2024.3457766.
- Zhang, S., Li, R., Wang, F.W., et al., 2019. Characteristics of landslides triggered by the 2018 Hokkaido Eastern Ibur earthquake, Northern Japan. *Landslides*, 16(9):1691–1708. DOI:10.1007/s10346-019-01207-6.
- Zhang, Z.X., Liu, Q.J., Wang, Y.H., 2018. Road Extraction by Deep Residual U-Net. *IEEE Geoscience and Remote Sensing Letters*, 15(5):749–753. DOI:10.1109/LGRS.2018.2802944.
- Zhao, W., Li, A.N., Nan, X., et al., 2017. Postearthquake Landslides Mapping From Landsat-8 Data for the 2015 Nepal Earthquake Using a Pixel-Based Change Detection Method. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5):1758–1768. DOI:10.1109/JSTARS.2017.2661802.

## 附中文参考文献

- 刘佳, 伍宇明, 高星, 等, 2022. 基于 GEE 和 U-net 模型的同震滑坡识别方法. *地球信息科学学报*, 24(7):1275–1285.
- 戴岚欣, 许强, 范宣梅, 等, 2017. 2017 年 8 月 8 日四川九寨沟地震诱发地质灾害空间分布规律及易发性评价初步研究. *工程地质学报*, 25(4):1151–1164.
- 窦杰, 向子林, 许强, 等, 2023. 机器学习在滑坡智能防灾减灾中的应用与发展趋势. *地球科学*, 48(5):1657.
- 许强, 董秀军, 李为乐, 2019. 基于天-空-地一体化的重大地质灾害隐患早期识别与监测预警. *武汉大学学报(信息科学版)*, 44(7):957–966.
- 陈博, 宋闯, 陈毅, 等, 2025. 2023 年甘肃积石山 Ms 6.2 地震同震滑坡和建筑物损毁情况应急识别与影响

因素研究. 武汉大学学报(信息科学版), 50(2):322-332.

陈立权, 赵超英, 任超锋, 等, 2020. 光学遥感用于贵州发耳镇尖山营滑坡监测研究. 中国岩溶, 39(4):518-523.