

辛鲁斌, 韩玲, 李良志. 基于多源数据融合的滑坡智能识别[J]. 地球科学与环境学报, 2023, 45(4): 920-928.

XIN Lu-bin, HAN Ling, LI Liang-zhi. Landslide Intelligent Recognition Based on Multi-source Data Fusion[J]. Journal of Earth Sciences and Environment, 2023, 45(4): 920-928.

DOI: 10.19814/j.jese.2022.11016

· 环境与可持续发展专刊 ·

基于多源数据融合的滑坡智能识别

辛鲁斌¹, 韩玲^{1,2,3*}, 李良志¹

(1. 长安大学地质工程与测绘学院, 陕西西安 710054; 2. 长安大学土地工程学院, 陕西西安 710054;
3. 陕西省土地整治重点实验室, 陕西西安 710054)

摘要: 滑坡灾害的识别与调查是防灾减灾工作的重要基础。传统的滑坡识别方法自动化程度较低, 但基于深度学习的滑坡智能识别自动化程度较高, 并且可以提高滑坡识别的精度与效率。首先, 引入光学遥感影像、数字高程模型 (DEM) 数据、地质数据与降雨数据构建滑坡多源数据集, 针对多源异构数据在量纲尺度上不统一的问题, 设计了多源异构数据预处理流程和融合模型; 其次, 构建了 Res-UNet 模型作为滑坡智能识别的网络模型, 并将训练集与测试集按照 8 : 2 的比例进行划分; 最后, 采用不同数据输入方式进行滑坡识别, 并将 Res-UNet 模型与主流的语义分割网络模型 FCN、U-Net 和 SegNet 进行对比。结果表明: 多源数据输入相比单一数据输入具有更好的滑坡识别结果, 在准确率 (Precision)、召回率 (Recall)、F1 分数 (F1-score) 和平均交并比 (MIoU) 上都有 5% 以上的提升; Res-UNet 模型的滑坡识别精度在 0.85 以上, 具有优异的滑坡识别能力, 可以为区域滑坡的快速准确识别提供技术支持。

关键词: 地质灾害; 滑坡识别; 深度学习; 特征提取; 语义分割; 多源数据; 残差网络; 遥感

中图分类号: P642.22; TP183

文献标志码: A

文章编号: 1672-6561(2023)04-0920-09

Landslide Intelligent Recognition Based on Multi-source Data Fusion

XIN Lu-bin¹, HAN Ling^{1,2,3*}, LI Liang-zhi¹

(1. School of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, Shaanxi, China;
2. School of Land Engineering, Chang'an University, Xi'an 710054, Shaanxi, China; 3. Shaanxi
Key Laboratory of Land Reclamation Engineering, Xi'an 710054, Shaanxi, China)

Abstract: The identification and investigation of landslide disasters are important basis for disaster prevention and mitigation. The traditional landslide recognition method has a low degree of automation, but the study on the intelligent landslide recognition model based on deep learning is very necessary for improving the accuracy and efficiency of landslide recognition. First of all, the optical remote sensing image, DEM data, geological data and rainfall data were introduced to construct landslide multi-source data set. Because multi-source heterogeneous data are not unified on the dimensional scale, the multi-source heterogeneous data preprocessing process and fusion model were designed. Secondly, the Res-UNet model is constructed as a network model for intelligent landslide recognition, and the training set and test set are divided by the ratio of 8 : 2.

收稿日期: 2022-11-07; 修回日期: 2023-02-24 投稿网址: <http://jese.chd.edu.cn/>

基金项目: 国家自然科学基金项目 (42171348)

作者简介: 辛鲁斌 (1999-), 男, 山东泰安人, 工学硕士研究生, E-mail: 2910213165@qq.com。

* 通讯作者: 韩玲 (1964-), 女, 辽宁沈阳人, 长安大学教授, 博士研究生导师, 工学博士, E-mail: hanling@chd.edu.cn。

Finally, different data inputs are used for landslide recognition, and the Res-UNet model is compared with the mainstream semantic segmentation network models (FCN, U-Net and SegNet). The results show that multi-source data input has better landslide recognition results than single data input, and has more than 5% improvement in precision, recall, F1-score and MIoU; the precision of the landslide identification results of Res-UNet model is above 0.85, and it has excellent landslide identification, which can provide technical support for rapid and accurate identification of regional landslides.

Key words: geological hazard; landslide identification; deep learning; feature extraction; semantic segmentation; multi-source data; residual network; remote sensing

0 引言

中国是地质灾害频发的国家,其中滑坡灾害发生频率最高,每年因滑坡灾害而引起的人员伤亡和财产损失不计其数,滑坡灾害的识别与调查是防灾减灾工作的重要基础^[1]。目前,滑坡灾害的识别主要包括滑坡的早期识别与监测以及已有滑坡的识别。传统依托于遥感影像目视解译与实地调查相结合的滑坡灾害调查方法需要消耗巨大的人力物力^[2-3];随着高性能遥感传感器的不断研发以及遥感卫星性能的不不断提升,遥感技术在地质灾害调查与研究中得到了普遍应用^[4-5]。

在3S技术的支撑下,滑坡的早期识别与监测预警取得了众多研究成果。例如,Li等通过研究滑坡的致灾因子与空间分布关系,划定了滑坡的易发区域,有利于滑坡的早期识别与监测^[6-7];张勤等认为基于GNSS的滑坡监测技术具有精度高、时效性好的特点,能够实现滑坡的精准预警^[8];朱武等结合空天地一体化的多源数据,构建多传感器集成的滑坡监测系统,成功预测了多起滑坡灾害^[9]。通过遥感影像实现已有滑坡灾害的识别主要有4种方法:人工目视解译、基于像元的滑坡识别、面向对象分析方法的滑坡识别以及基于深度学习的滑坡识别。人工目视解译是专业人员通过对遥感影像的纹理、形状、色调等信息的判别^[10],结合滑坡的地学特征信息来识别滑坡;这种滑坡识别方法效率较低,不能满足大范围的研究需求。基于像元和面向对象分析方法的滑坡识别本质上是遥感影像的地物分类。Keyport等对基于像元和面向对象分析方法的滑坡识别结果进行了对比分析,发现面向对象分析方法能识别出更多的滑坡^[11]。丁永辉等采用面向对象分析方法,结合滑坡灾害的光谱、纹理、形状等特征实现滑坡的信息提取,以金沙江流域部分区段为研究对象进行滑坡识别,取得了较好的滑坡识别效果^[12]。基于像

元与面向对象分析方法的滑坡识别主要依据的是滑坡的浅层信息,没有利用上下文关系的高级语义信息,对滑坡特征的表达能力有限,同时受同物异谱、同谱异物以及混合像元的影响,限制了滑坡识别精度的提升。

随着人工智能技术的迅速发展,深度学习在计算机视觉领域取得了重大成果,其特征提取能力与学习能力较强,将深度学习应用于滑坡识别的研究在近年来也取得了较大进展。例如,杨昭颖等将卷积神经网络应用于黄土滑坡的识别,利用GF-1影像与数字高程模型(Digital Elevation Model, DEM)构建滑坡数据集,取得了较高的识别精度^[13];Haciefendioglu等使用飞机获取滑坡的航摄影像,将自制滑坡数据集加入非滑坡场景图像,使用Visual Geometry Group-19(VGG-19)和Residual Neural Network-50(ResNet-50)网络进行滑坡识别,都取得了90%以上的成功率^[14];Pang等使用日本北海道地区的遥感影像制作了滑坡的样本数据集,通过YOLOV3算法构建了滑坡识别模型,实现了对滑坡的目标检测^[15];蔡浩杰等将遥感影像与地形因子相结合,应用卷积神经网络实现滑坡识别^[16];刘佳等基于Google Earth Engine(GEE)云平台结合U-Net网络模型完成Landsat影像的滑坡识别,发现采用影像数据、高程、坡度与归一化植被指数(Normalized Difference Vegetation Index, NDVI)的多源数据输入具有最高的识别精度^[17]。

近年来,基于深度学习的语义分割与目标检测方法被广泛应用,但现有的深度学习网络模型通常仅使用遥感影像作为已有滑坡识别的数据源,缺少滑坡致灾因子的特征表达。同时,卷积神经网络(Convolutional Neural Network, CNN)随网络深度的增加而引起网络退化问题以及特征空间中与滑坡识别无关的冗余信息的存在,限制了网络的滑坡识别效率与精度。基于此,本文采用光学遥感影像、

DEM 数据、地质数据和降雨数据构建滑坡识别的多源数据集,为使多源数据更好地应用到滑坡识别中,设计了基于深度学习的多源数据融合网络;同时,引入残差网络与卷积注意力机制模块(Convolutional Block Attention Module,CBAM),并提出了一种基于卷积神经网络的滑坡识别模型;通过自制的滑坡数据集进行训练,得到最优的网络模型,以期实现滑坡的准确识别,为大范围的滑坡调查提供有力支撑。

1 数据来源与处理

1.1 数据来源

传统的滑坡识别方法仅依靠光学遥感影像分析其光谱特性、纹理特征等,并未考虑其他因子对滑坡的影响。植被覆盖密集、干扰特征多等问题导致难以从光学遥感影像中准确识别部分滑坡,因此,在滑坡识别中需要考虑其他因子。例如,DEM 数据可以获取滑坡的坡度、坡向等特征,表征地形特征且不受植被覆盖影响;区域地质条件与降雨是常见的滑坡诱发因素,在滑坡识别中考虑这些因素有积极的作用^[18]。因此,本文采用了除光学遥感影像以外的其他数据源,包括 DEM 数据、地质数据和降雨数据,共同构建滑坡识别的多源数据集。数据来源如表 1 所示。光学遥感影像来源包括无人机航摄影像(空间分辨率为 0.2 m)、四川及周边滑坡泥石流灾害高精度航空影像及解译数据集^[19](空间分辨率为 0.2~0.9 m)、Google Earth 卫星影像(空间分辨率为 0.3 m)。

表 1 数据来源	
Table 1 Data Sources	
多源异构数据	数据来源
光学遥感影像	无人机航摄影像、公开的滑坡数据集、Google Earth 卫星影像
DEM 数据	美国航空航天局(NASA)12.5 m DEM
地质数据	1:200 000 地质图
降雨数据	1 km 分辨率降雨量

1.2 数据处理

由于多源异构数据在量纲尺度上并不统一,不能直接输入到网络模型中,所以数据处理主要包括多源异构数据的一致性统一和滑坡数据集的制作。多源异构数据处理流程如图 1 所示。DEM 数据与降雨数据首先进行归一化处理,选用 Z-score 标准化方法^[20]进行计算;然后将归一化后的数据以栅格形式保存。Z-score 标准化方法的表达式为

$$z=\frac{m-\mu}{\sigma}$$

(1)

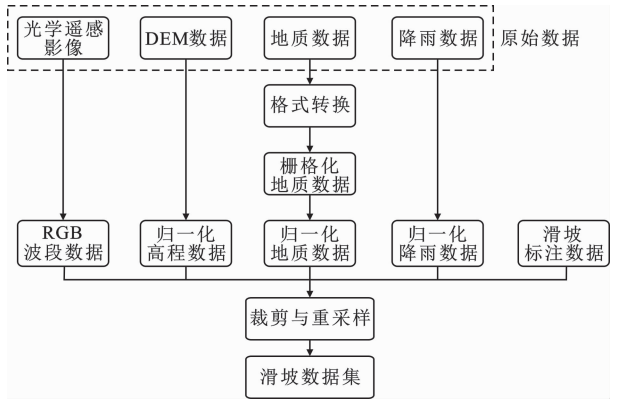


图 1 数据处理流程

Fig. 1 Data Processing Flow Chart

式中: z 表示归一化后的值; m 表示数据的原始值; μ 表示总体数据的平均值; σ 表示总体数据的标准差。

地质数据是由地质图经过格式转换后根据地质年代与岩性进行分组^[21],然后根据其组数进行栅格化与归一化,最终得到网络输入所需的数据格式。为保留滑坡原始的光谱特性,光学遥感影像则不再进行处理。

滑坡数据集由光学遥感影像、DEM 数据、地质数据、降雨数据和滑坡标注数据共同构成。本文使用 Labelme 软件进行人工标注,得到滑坡的标签图,共生成1 200组有滑坡样本,并制作相同数量的无滑坡样本。为便于网络训练,将影像样本大小裁剪为 256×256,裁剪相应范围的 DEM 数据、地质数据与降雨数据并将其重采样为 256×256。

2 分析方法

本文所采用的深度学习网络模型结合了 Res-Net 残差网络、U-Net 网络与卷积注意力机制模块:采用卷积神经网络和通道注意力机制构建多源数据融合网络,将 ResNet50 作为网络特征提取部分,对多源数据融合结果进行特征提取;选用 U-Net 网络的解码器用于恢复图像尺寸,加入卷积注意力机制模块(包含通道注意力模块与空间注意力模块)抑制无关信息的影响,在小幅增加计算量和参数数量的前提下,能够大幅提升模型的性能。基于多源异构数据融合的滑坡识别网络模型如图 2 所示。

2.1 ResNet 残差网络

卷积神经网络的网络深度对结果的精度有很大影响。浅层网络提取的特征抽象程度不高,而深层网络从原始特征逐步提取到深层抽象的特征,提取的特征更加丰富。但随着网络深度的不断增加,其网络精度不仅没有提高甚至出现下降,网络出现了

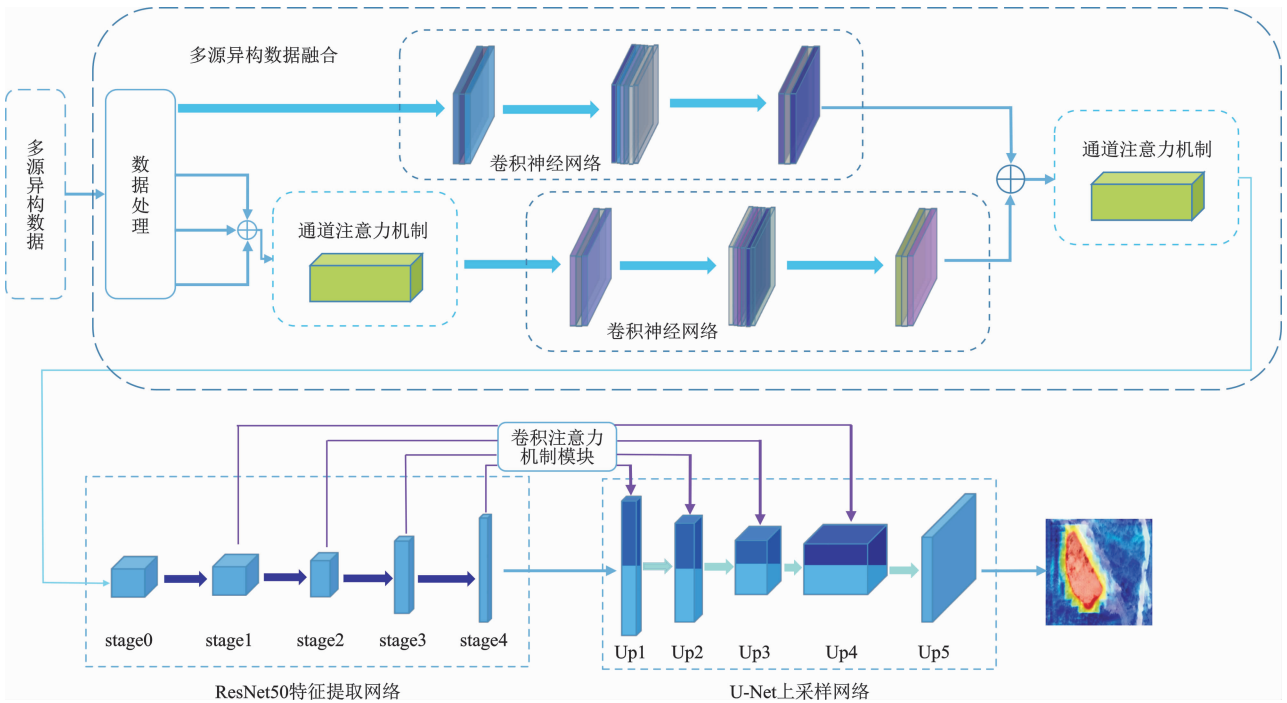


图 2 基于多源异构数据融合的滑坡识别网络模型

Fig. 2 Landslide Identification Network Model Based on Multi-source Heterogeneous Data Fusion

退化现象。

残差网络最先是由 He 等提出来的^[22]，基本的网络结构主要是由残差块构成的，能够很好地优化由于网络深度增加而引起的网络退化问题。跳跃连接的使用能够使底层的输入特征不经过中间层直接与后续层相连接，保证网络深度复杂性的同时并不会带来额外的参数与计算，既提取了深层网络特征，又保留了残差块原始的输入特征。残差网络结构如图 3 所示，其输出由两部分组成，即输入特征 x 和经过两个权重层得到的残差 $F(x)$ ，两者具有相同的特征维度。

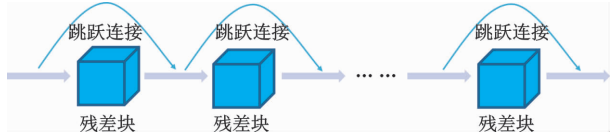


图 3 残差网络结构示意图

Fig. 3 Schematic View of Residual Network Structure

2.2 卷积注意力机制模块

注意力机制最早是图像视觉领域专家提出来的。在面对海量图像信息时，人的视觉能聚焦于一个感兴趣的区域，注意力机制能帮助网络聚焦于重要的特征信息，弱化无关冗余信息的影响，从而更好地提高网络的性能。

卷积注意力机制模块结合了通道注意力机制和空间注意力机制^[23]，其结构如图 4 所示。通道注意

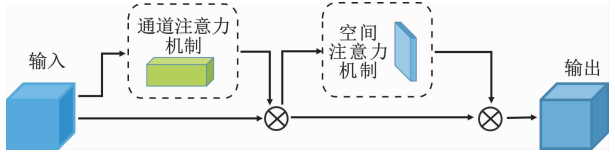


图 4 卷积注意力机制模块结构

Fig. 4 Structure of CBAM

力机制通过全局最大池化和平均池化后，连接多层感知机 (Multilayer Perceptron, MLP) 与激活层得到各特征图层的权重值 (即重要性)，最后将输入的各特征图层与对应权重值相乘，突出重要的特征通道，弱化对识别任务作用较小的特征通道。空间注意力机制通过沿通道方向上的最大池化与平均池化后，连接一个卷积层和激活层得到特征图层各位置的权重值，最后将输入的特征图层与对应位置上权重值相乘，突出包含更多有效信息的空间位置，抑制其他位置特征信息的影响。

2.3 基于深度学习的滑坡识别模型

本文提出的滑坡识别模型采用 ResNet50 作为特征提取网络，结合 U-Net 网络的解码器结构并融入卷积注意力机制模块。融入卷积注意力机制模块的 Res-UNet 网络结构如表 2 与图 5 所示。特征提取网络可以分为 5 个阶段，其中 Stage0 包括卷积、池化两层，Stage1、Stage2、Stage3、Stage4 分别包括 3、4、6、3 个 Bottleneck 残差块。解码器主要包括卷积层和上采样操作，逐阶段地扩大特征图尺寸直至

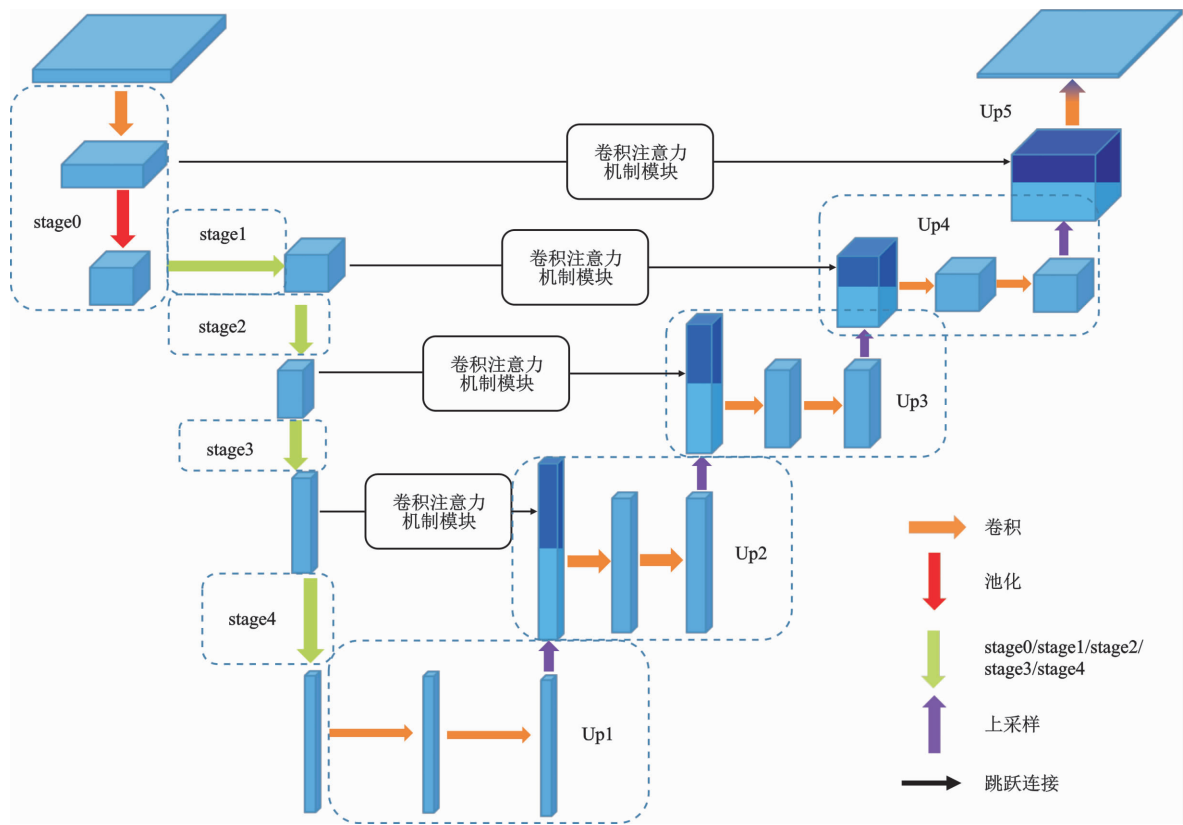


图 5 融入卷积注意力机制模块的 Res-UNet 模型网络结构示意图

Fig. 5 Schematic View of Res-UNet Model Network Structure Integrated with CBAM

恢复原输入尺寸大小。ResNet50 各阶段提取的特征通过卷积注意力机制模块经跳跃连接与上采样网络提取的特征进行拼接。

3 结果分析

为了克服单一光学遥感影像进行滑坡识别的局限性,本文构建了包含光学遥感影像、DEM 数据、地质数据与降雨数据的多源异构数据集。实验数据按照训练集与测试集 8 : 2 的比例进行划分,尺寸大小为 256 × 256。由于数据集样本数量有限,所以在模型训练阶段对数据进行裁剪、旋转、添加噪声等数据增强操作,以提高网络模型的泛化能力。本实验所用的计算机操作系统为 Windows 10, GPU 为 NVIDIA GTX3060 16GB, CPU 为 i7 11700, 内存为 16 GB。

3.1 精度指标

本文将滑坡识别任务作为二分类的语义分割问题进行实验研究,将像素点划分为滑坡点与非滑坡点。混淆矩阵是用来记录分类器分类结果的一种标准格式(表 3)。本文选择常用的语义分割问题的精度指标,包括准确率(Precision)、召回率(Recall)、F1 分数(F1-score)、平均交并比(MIoU)等,作为滑

坡识别结果的定量评价指标^[24]。

准确率是正确预测的滑坡点数量与预测的总滑坡点数量的比值。其表达式为

$$P_r = \frac{S_{TP}}{S_{TP} + S_{FP}} \tag{2}$$

式中: P_r 为准确率; S_{TP} 为正确预测的滑坡点数量; S_{FP} 为标注为非滑坡,但预测为滑坡的点数量。

召回率是正确预测的滑坡点数量与标签的总滑坡点数量的比值。其表达式为

$$S = \frac{S_{TP}}{S_{TP} + S_{FN}} \tag{3}$$

式中: S 为召回率; S_{FN} 为标注为滑坡,但预测为非滑坡的点数量。

F1 分数(F_1)综合了准确率与召回率,取两者的调和平均数,能从整体上反映滑坡识别的效果。其表达式为

$$F_1 = 2 \times \frac{P_r S}{P_r + S} \tag{4}$$

平均交并比是滑坡点与非滑坡点数量交并比的平均值。其表达式为

$$R_{MIoU} = \frac{1}{2} \times \left(\frac{S_{TP}}{S_{TP} + S_{FN} + S_{FP}} + \frac{S_{TN}}{S_{TN} + S_{FN} + S_{FP}} \right) \tag{5}$$

表 2 融入卷积注意力机制模块的 Res-UNet 模型网络结构

Table 2 Res-UNet Model Network Structure Integrated into CBAM			
阶段	输入尺寸	输出尺寸	结构
Stage0	$6 \times 256 \times 256$	$64 \times 64 \times 64$	Conv2d; $7 \times 7, 64, \text{stride } 2$ MaxPool2d; $3 \times 3, \text{stride } 2$
Stage1	$64 \times 64 \times 64$	$256 \times 64 \times 64$	$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$
Stage2	$256 \times 64 \times 64$	$512 \times 32 \times 32$	$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 512 \end{bmatrix} \times 4$
Stage3	$512 \times 32 \times 32$	$1\ 024 \times 16 \times 16$	$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1\ 024 \end{bmatrix} \times 6$
Stage4	$1\ 024 \times 16 \times 16$	$2\ 048 \times 8 \times 8$	$\begin{bmatrix} 1 \times 1 & 512 \\ 3 \times 3 & 512 \\ 1 \times 1 & 2\ 048 \end{bmatrix} \times 3$
Up1	$2\ 048 \times 8 \times 8$	$1\ 024 \times 16 \times 16$	Conv2d; $3 \times 3, 1\ 024, \text{stride } 1$ Conv2d; $3 \times 3, 1\ 024, \text{stride } 1$ Upsampling; factor 2
Up2	$2\ 048 \times 16 \times 16$	$512 \times 32 \times 32$	Conv2d; $3 \times 3, 512, \text{stride } 1$ Conv2d; $3 \times 3, 512, \text{stride } 1$ Upsampling; factor 2
Up3	$1\ 024 \times 32 \times 32$	$256 \times 64 \times 64$	Conv2d; $3 \times 3, 256, \text{stride } 1$ Conv2d; $3 \times 3, 256, \text{stride } 1$ Upsampling; factor 2
Up4	$512 \times 64 \times 64$	$64 \times 128 \times 128$	Conv2d; $3 \times 3, 64, \text{stride } 1$ Conv2d; $3 \times 3, 64, \text{stride } 1$ Upsampling; factor 2
Up5	$128 \times 128 \times 128$	$1 \times 256 \times 256$	Conv2d; $3 \times 3, 32, \text{stride } 1$ Upsampling; factor 2 Conv2d; $1 \times 1, 1, \text{stride } 1$

注:Conv2d 为二维卷积;stride 为步长;MaxPool2d 为二维最大池化;Upsampling 为上采样;factor 为倍数。

表 3 混淆矩阵

Table 3 Confusion Matrix		
标签	预测结果	
	滑坡	非滑坡
滑坡	TP	FN
非滑坡	FP	TN

注:TP 是指标签滑坡,也正确预测为滑坡的像素点数量;FP 是指标签非滑坡,被错误预测为滑坡的像素点数量;FN 是指标签滑坡,被错误预测为滑坡的像素点数量;TN 是指标签非滑坡,也正确预测为非滑坡的像素点数量。

式中: R_{MIoU} 为平均交并比; S_{TN} 为正确预测的非滑坡点数量。

3.2 多源数据验证

本文采用光学遥感影像、DEM 数据、地质数据和降雨数据共同构建了滑坡的多源异构数据集,为了验证多源数据的输入对滑坡识别结果的影响,共设置了 3 组实验。网络模型选取融入卷积注意力机制模块的 Res-UNet,优化算法均采用 RMSprop 算法,学习率为 0.000 1,权重衰减为 10^{-8} ,冲量为 0.9,损失函数采用二元交叉熵。在实验过程中,设置不同的批大小(Batch Size)和时期(Epoch),并记录实验结果。实验结果最优时,设置的批大小为 12,时期为 100,损失函数与准确率随训练轮数的变化如图 6 所示。

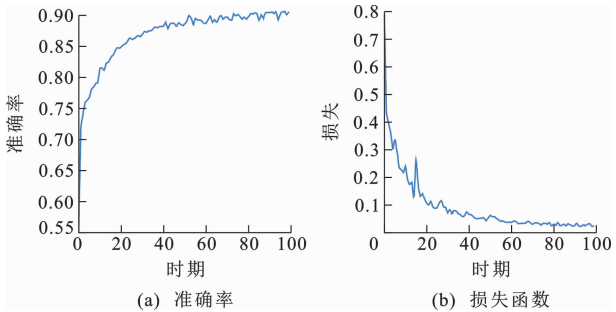


图 6 训练准确率与损失函数变化

Fig. 6 Variations of Training Accuracy and Loss Function

3 组实验数据输入分别为:第一组,光学遥感影像;第二组,DEM 数据+地质数据+降雨数据;第三组,光学遥感影像+DEM 数据+地质数据+降雨数据。实验结果的精度评价如表 4 所示。实验结果表明:多源数据相较于单一数据在滑坡识别的精度上有较大的提升;仅依靠 DEM 数据、地质数据和降雨数据识别结果精度差,不能准确完成滑坡的识别;仅通过单一的光学遥感影像进行滑坡识别也有较高的识别精度,说明光学遥感影像在滑坡识别中发挥着重要作用。

表 4 不同数据输入的实验结果

Table 4 Experimental Results of Different Data Inputs				
数据输入方式	准确率	召回率	F1 分数	平均交并比
第一组	0.839 8	0.760 0	0.797 9	0.814 0
第二组	0.570 3	0.426 3	0.487 9	0.496 8
第三组	0.899 1	0.853 4	0.875 7	0.876 9

3.3 网络模型对比

根据常用的语义分割网络模型 FCN、U-Net 和 SegNet 设计了多组滑坡识别实验,优化算法均采用 RMSprop 算法,具体参数设置不变,损失函数采用二元交叉熵。将 U-Net、FCN、SegNet 与 Res-UNet 模型在训练数据集上分别进行训练,在测试数据集

上进行滑坡识别实验,得到识别结果的精度如表 5 所示。

表 5 不同网络模型实验结果

网络模型	准确率	召回率	F1 分数	平均交并比
U-Net 模型	0.811 8	0.737 6	0.772 9	0.792 8
FCN 模型	0.856 1	0.618 2	0.718 0	0.757 7
SegNet 模型	0.845 0	0.610 0	0.708 5	0.749 0
Res-UNet 模型	0.899 1	0.853 4	0.875 7	0.876 9

U-Net、FCN、SegNet 和 Res-UNet 等 4 种网络模型的滑坡识别效果如图 7 所示。以陕西志丹地区的两处滑坡 a、c 和三峡库区巴东地区的一处滑坡 b 为例,通过对比可以发现 Res-UNet 模型的滑坡识别效果最佳。相比之下,U-Net、FCN 和 SegNet 模型在一定程度上不能很好地完成滑坡的精确识别,存在错分、漏分现象。

从上述 4 种深度学习网络模型的滑坡识别结果来看,本文提出的融入卷积注意力机制模块的 Res-UNet 模型相较于其他网络模型在各项精度指标上均有显著的提升,在识别效果上也明显优于其他网络模型。

3.4 网络连接方法对比

本文提出的 Res-UNet 模型主要包括下采样和上采样两部分。为了验证将卷积注意力机制模块嵌入到跳跃连接中是否有助于模型性能的提升,本文进行了消融实验。连接方法分别为通道方向上的简单拼接与嵌入卷积注意力机制模块的跳跃连接。实验结果的精度评价如表 6 所示。结果表明:嵌入卷积注意力机制模块的跳跃连接能有效提升网络模型的滑坡识别能力。

表 6 不同连接方法的实验结果

Table 6 Experimental Results of Different Connection Methods				
连接方法	准确率	召回率	F1 分数	平均交并比
通道拼接	0.874 4	0.732 1	0.797 0	0.810 3
跳跃连接	0.899 1	0.853 4	0.875 7	0.876 9

4 结 语

(1)将本文构建的滑坡智能识别网络模型——Res-UNet 模型与主流的语义分割网络模型 U-Net、FCN 和 SegNet 进行对比实验可以发现,Res-UNet 模型的滑坡识别结果的准确率、召回率、F1 分数和平均交并比均在 0.85 以上,相比 U-Net、FCN 和 SegNet 网络模型有明显的精度提升,具有优异的滑

坡识别能力。针对卷积注意力机制模块设置消融实验,结果表明将卷积注意力机制模块嵌入到上、下采样网络的跳跃连接中具有更好的滑坡识别精度,可以增强网络模型的滑坡识别能力。

(2)为了提高滑坡识别的精度与置信度,在光学遥感影像的基础上引入 DEM 数据、降雨数据和地质数据,探索了基于深度学习的多源异构数据深度融合。与单一数据输入相比,多源数据输入的滑坡识别结果的各项精度指标均有 6%~10%的提升,表明多源数据比单一数据具有更好的滑坡识别精度。但受限于 DEM 数据、降雨数据和地质数据的分辨率以及多源数据融合方法等因素的影响,将多源数据应用于滑坡识别中仍有很大的提升空间。

参 考 文 献 :

References :

[1] 孙萍萍,张茂省,贾俊,等.中国西部黄土区地质灾害调查研究进展[J].西北地质,2022,55(3):96-107.
SUN Ping-ping,ZHANG Mao-sheng,JIA Jun,et al. Geo-hazards Research and Investigation in the Loess Regions of Western China[J].Northwestern Geology,2022,55(3):96-107.

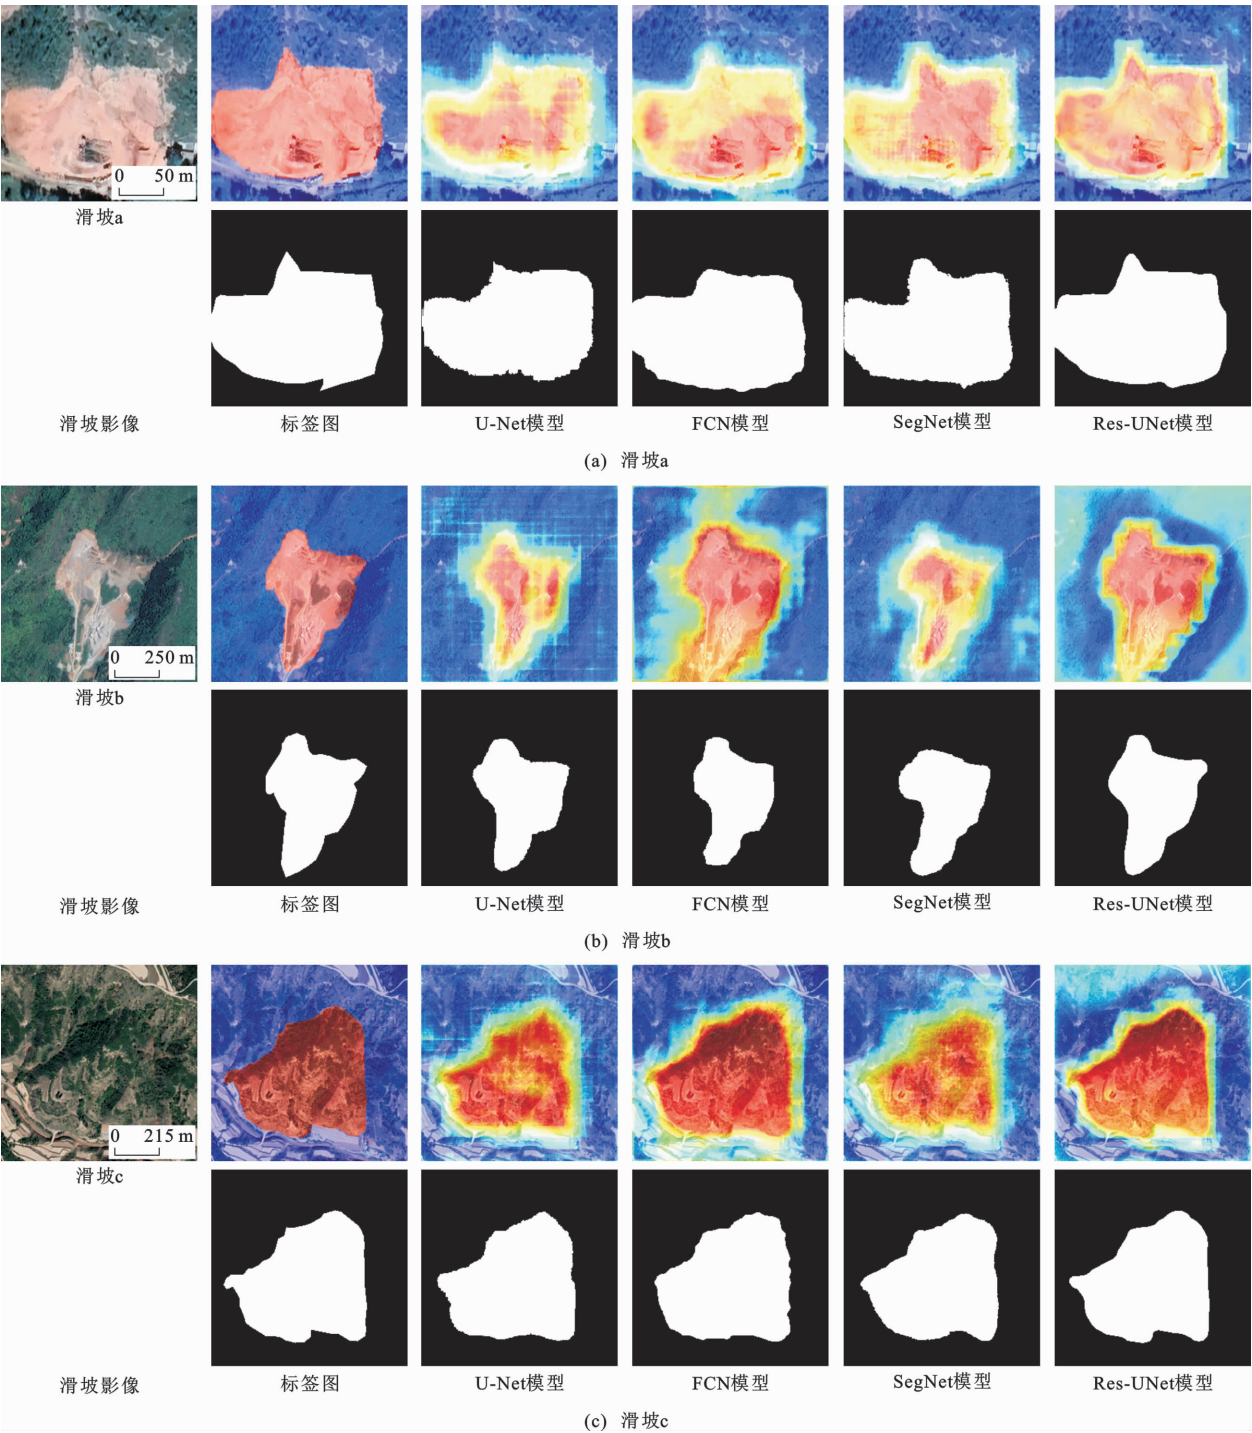
[2] HEIDARZADEH M,MIYAZAKI H,ISHIBE T,et al. Field Surveys of September 2018 Landslide-generated Waves in the Apporo Dam Reservoir, Japan: Combined Hazard from the Concurrent Occurrences of a Typhoon and an Earthquake[J].Landslides,2023,20(1):143-156.

[3] 李阳,张建军,魏广阔,等.晋西黄土区极端降雨后浅层滑坡调查及影响因素分析[J].水土保持学报,2022,36(5):44-50.
LI Yang,ZHANG Jian-jun,WEI Guang-kuo,et al. Investigation of Shallow Landslide After Extreme Rainfall and Analysis of Its Influencing Factors in the West Shanxi Loess Region[J].Journal of Soil and Water Conservation,2022,36(5):44-50.

[4] CHEN Y Y,MING D P,LING X,et al. Landslide Susceptibility Mapping Using Feature Fusion-based CPCNN-ML in Lantau Island,Hong Kong[J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2021,14:3625-3639.

[5] GIORDAN D,LUZI G,MONSERRAT O,et al. Remote Sensing Analysis of Geologic Hazards[J].Remote Sensing,2022,14(19):4818.

[6] LI L P,LAN H X,GUO C B,et al. A Modified Frequency Ratio Method for Landslide Susceptibility Assessment[J].Landslides,2017,14(2):727-741.



滑坡 a、c 位于陕西志丹地区;滑坡 b 位于三峡库区巴东地区

图 7 不同网络模型滑坡识别结果对比

Fig. 7 Comparisons of Landslide Identification Results of Different Network Models

[7] LAN H X,ZHOU C H,WANG L J,et al. Landslide Hazard Spatial Analysis and Prediction Using GIS in the Xiaojiang Watershed, Yunnan, China [J]. Engineering Geology,2004,76(1/2):109-128.

[8] 张 勤,白正伟,黄观文,等. GNSS 滑坡监测预警技术进展[J]. 测绘学报,2022,51(10):1985-2000.

ZHANG Qin, BAI Zheng-wei, HUANG Guan-wen, et al. Review of GNSS Landslide Monitoring and Early Warning[J]. Acta Geodaetica et Cartographica Sinica,2022,51(10):1985-2000.

[9] 朱 武,张 勤,朱建军,等. 特大滑坡实时监测预警与技术装备研发[J]. 岩土工程学报,2022,44(7):1341-1350.

ZHU Wu, ZHANG Qin, ZHU Jian-jun, et al. Real-

- time Monitoring and Early Warning Technology for Huge Landslides[J]. Chinese Journal of Geotechnical Engineering, 2022, 44(7): 1341-1350.
- [10] HE F, TAN S C, LIU H J. Mechanism of Rainfall Induced Landslides in Yunnan Province Using Multi-scale Spatio-temporal Analysis and Remote Sensing Interpretation [J]. Microprocessors and Microsystems, 2022, 90: 104502.
- [11] KEYPORT R N, OOMMEN T, MARTHA T R, et al. A Comparative Analysis of Pixel- and Object-based Detection of Landslides from Very High-resolution Images[J]. International Journal of Applied Earth Observation and Geoinformation, 2018, 64: 1-11.
- [12] 丁永辉, 张 勤, 杨成生, 等. 基于高分遥感金沙江流域滑坡识别: 以巴塘县王大龙村为例[J]. 测绘通报, 2022(4): 51-55.
- DING Yong-hui, ZHANG Qin, YANG Cheng-sheng, et al. Landslide Identification in Jinsha River Basin Based on High-resolution Remote Sensing: Taking Wangdalong Village of Batang County as an Example [J]. Bulletin of Surveying and Mapping, 2022(4): 51-55.
- [13] 杨昭颖, 韩灵怡, 郑向向, 等. 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[J]. 自然资源遥感, 2022, 34(2): 224-230.
- YANG Zhao-ying, HAN Ling-yi, ZHENG Xiang-xiang, et al. Landslide Identification Using Remote Sensing Images and DEM Based on Convolutional Neural Network: A Case Study of Loess Landslide [J]. Remote Sensing for Natural Resources, 2022, 34(2): 224-230.
- [14] HACIEFENDIOGLU K, DEMIR G, BAŞAGA H B. Landslide Detection Using Visualization Techniques for Deep Convolutional Neural Network Models[J]. Natural Hazards, 2021, 109(1): 329-350.
- [15] PANG D D, LIU G, HE J, et al. Automatic Remote Sensing Identification of Co-seismic Landslides Using Deep Learning Methods[J]. Forests, 2022, 13(8): 1213.
- [16] 蔡浩杰, 韩海辉, 张雨莲, 等. 基于地形特征融合的卷积神经网络滑坡识别[J]. 地球科学与环境学报, 2022, 44(3): 568-579.
- CAI Hao-jie, HAN Hai-hui, ZHANG Yu-lian, et al. Convolutional Neural Network Landslide Recognition Based on Terrain Feature Fusion[J]. Journal of Earth Sciences and Environment, 2022, 44(3): 568-579.
- [17] 刘 佳, 伍宇明, 高 星, 等. 基于 GEE 和 U-Net 模型的同震滑坡识别方法[J]. 地球信息科学学报, 2022, 24(7): 1275-1285.
- LIU Jia, WU Yu-ming, GAO Xing, et al. Image Recognition of Co-seismic Landslide Based on GEE and U-Net Neural Network[J]. Journal of Geo-information Science, 2022, 24(7): 1275-1285.
- [18] WANG H J, ZHANG L M, YIN K S, et al. Landslide Identification Using Machine Learning[J]. Geoscience Frontiers, 2021, 12(1): 351-364.
- [19] 曾 超, 曹振宇, 苏凤环, 等. 四川及周边滑坡泥石流灾害高精度航空影像及解译数据集(2008~2020 年)[J]. 中国科学数据, 2022, 7(2): 195-205.
- ZENG Chao, CAO Zhen-yu, SU Feng-huan, et al. A Dataset of High-precision Aerial Imagery and Interpretation of Landslide and Debris Flow Disaster in Sichuan and Surrounding Areas Between 2008 and 2020 [J]. China Scientific Data, 2022, 7(2): 195-205.
- [20] 杨寒雨, 赵晓永, 王 磊. 数据归一化方法综述[J]. 计算机工程与应用, 2023, 59(3): 13-22.
- YANG Han-yu, ZHAO Xiao-yong, WANG Lei. Review of Data Normalization Methods[J]. Computer Engineering and Applications, 2023, 59(3): 13-22.
- [21] 张庭瑜, 毛忠安, 孙增慧. 基于径向神经网络耦合确定性指数的滑坡易发性分区研究[J]. 长江科学院院报, 2021, 38(11): 64-72.
- ZHANG Ting-yu, MAO Zhong-an, SUN Zeng-hui. Landslide Susceptibility Mapping Using Radial Basis Function Neural Network Coupling Certainty Factor [J]. Journal of Yangtze River Scientific Research Institute, 2021, 38(11): 64-72.
- [22] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]// IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C]// FERRARI V, HEBERT M, SMINCHISCU C, et al. Computer Vision-ECCV 2018. Munich: Springer, 2018: 3-19.
- [24] SHAO Z F, ZHOU Z F, HUANG X, et al. MRENet: Simultaneous Extraction of Road Surface and Road Centerline in Complex Urban Scenes from Very High-resolution Images[J]. Remote Sensing, 2021, 13(2): 239.