

基于多源数据融合的山体滑坡研究

刁君华¹, 冯向萍¹, 马新春^{1,2}

(1. 新疆农业大学 计算机与信息工程学院, 新疆 乌鲁木齐 830052;

2. 新疆电子研究所股份有限公司, 新疆 乌鲁木齐 830013)

摘要: 山体滑坡是一种频发的地质灾害, 通过对滑坡的识别来进行灾害防治是一项重要的任务。目前, 单一的数据源使得滑坡识别效率较低, 仅从滑坡遥感影像上来进行滑坡研究, 无法充分识别坡度、坡向和高度变化等地形特征。针对于此, 实验结合滑坡遥感影像和 DEM 数据进行研究, 设计了一个不共享权重的孪生网络, 对两类多源异质数据进行特征融合。其次, 使用一种基于注意力机制改进的 DeeplabV3+语义分割模型进行分割研究, 并将改进模型与 FCN、Unet、SegNet 和 AED-Net 等语义分割模型进行对比。实验结果表明, 多源数据的融合相比于单一数据具有更好的滑坡分割效果, 在精确率 (Precision)、召回率 (Recall)、F1 分数 (F1-score) 和平均交并比 (MIoU) 上分别提高了 3.5 百分点、4.9 百分点、4.2 百分点和 3.1 百分点。引入注意力机制的 DeepLabV3+模型的 F1-score 和 MIoU 比原模型分别提高了 1.6 百分点和 1.1 百分点。

关键词: 滑坡识别; 多源数据; 特征融合; 孪生网络; 注意力机制; 语义分割

中图分类号: TP181

文献标识码: A

文章编号: 1673-629X(2025)04-0214-07

doi:10.20165/j.cnki.ISSN1673-629X.2024.0385

Research on Landslides Based on Multi-source Data Fusion

DIAO Jun-hua¹, FENG Xiang-ping¹, MA Xin-chun^{1,2}

(1. School of Computer and Information Engineering, Xinjiang Agricultural University, Urumqi 830052, China;

2. Xinjiang Electronics Research Institute Co., Ltd., Urumqi 830013, China)

Abstract: Landslide is a frequent geological disaster. It is an important task to prevent and control landslides by identifying them. At present, the efficiency of landslide identification is low due to the single data source. Landslide research based on landslide remote sensing images alone cannot fully identify terrain features such as slope, direction and height change. In this experiment, landslide remote sensing images and DEM data were combined for research, and a twin network without shared weights was designed to fuse the features of two multi-source heterogeneous data. Secondly, a DeeplabV3+ semantic segmentation model based on the improved attention mechanism was used for segmentation research, and the improved model was compared with the FCN, Unet, SegNet and AED-Net and other semantic segmentation models. The experimental results show that the fusion of multi-source data has better landslide segmentation effect than single data, and the Precision, Recall, F1-score and mean intersection over union (MIoU) are improved by 3.5 percentage points, 4.9 percentage points, 4.2 percentage points and 3.1 percentage points, respectively. The F1-score and MIoU of the DeepLabV3+ model with the introduction of the attention mechanism are respectively improved by 1.6 percentage points and 1.1 percentage points compared with the original model.

Key words: landslide identification; multi-source data; feature fusion; twin network; attention mechanism; semantic segmentation

0 引言

滑坡是全球最常见的地质灾害之一, 它在短时间内可以摧毁房屋和生命财产, 同时破坏周边的生态环境, 从而对自然资源、人类生命和财产造成严重的破坏^[1]。研究人员通过对其发生的可能性做出科学的评

价来进行滑坡的预测, 从而预防灾害的发生, 但是滑坡地质灾害的形成原因较为复杂, 难以及时定点地准确预报, 所以准确的进行滑坡识别已成为自然灾害有关部门重点关注的问题。

随着数据驱动技术的快速发展和空间探测技术的

收稿日期: 2024-10-10

修回日期: 2025-02-11

基金项目: 新疆维吾尔自治区科技支疆项目计划 (2022E02080)

作者简介: 刁君华 (2000-), 女, 硕士研究生, 研究方向为机器学习、深度学习; 通讯作者: 冯向萍 (1973-), 女, 教授, 硕士, 研究方向为机器学习、深度学习。

升级,滑坡预测逐渐依赖于各种数据源的综合分析。由于滑坡发生的诱因和影响因素非常复杂,需要从多种数据中提取相关信息,越来越多的监测设备也随之产生,基于传感器^[2]、InSAR^[3-4]、激光雷达^[5]等监测到的数据,主要可分为结构化数据和非结构化数据。传统的滑坡分类检测方法以机器学习^[6-8]为主,通过应用气象数据、地质特征和降雨记录等结构化数据对滑坡发生的概率及位移等做出预测。Wu 等人^[9]综合了地质、环境条件、人类工程活动和降雨条件等 10 个因素采用随机森林模型来预测川西木里县的滑坡易发性,并输出因子权重和模型精度。Xu 等人^[10]基于滑坡位移预测方法解决短期位移预测精度不足的问题,比较了预测值的偏差、相对误差(RE),使用 XGBoost、SVR 和 RNN 获得滑坡位移的实际值。结果表明,使用 XGBoost 和 SVR 进行边坡位移预测的精度非常高,其中 XGBoost 算法的位移预测效果优于 SVR 和 RNN 在滑坡滑动过程中的作用。Wu 等人^[11]通过创建滑坡清单,确定了滑坡的诱发因素,使用 K-means 聚类对数据因子进行净化,并使用机器学习模型、随机森林(RF)和人工神经网络(ANN)对滑坡易发性评价进行比较研究。采用 K-means 方法对非滑坡样本数据进行净化,对于滑坡敏感性图的绘制具有重要意义。

近年来,随着人工智能技术的发展,深度学习方法^[12-14]被应用于遥感影像、激光雷达影像、高光谱影像等非结构化数据来进行滑坡的识别与研究。如蒋伟杰等人^[15]提出了 AED-Net 网络,使用浅层特征提取网络缓解深度神经网络造成的边界模糊问题,利用空洞空间卷积池化金字塔结构的多尺度特征提取能力,结果表明该模型在滑坡识别上取得了优异的成果。He 等人^[16]提出基于 MLP 模型构建 LSA 阈值模型识

别潜在的滑坡区域,使用 InSAR 数据进行评估,可以快速确定潜在滑坡的空间位置,为快速早期滑坡识别提供技术支持。Lv 等人^[17]基于光学遥感图像的滑坡检测问题,针对滑坡的形状信息,提出了一种形状增强视觉变换器(ShapeFormer)模型,为了进行特征提取,引入了金字塔视觉变换器(PVT)模型,实验结果表明该模型在处理遥感图像滑坡检测问题时具有一定的优势。Zhou 等人^[18]提出了一种多尺度注意力分段网络(MsASNet),该网络获取不同尺度的遥感图像特征,设计了一种编码器-解码器结构来加强滑坡边界,并结合信道注意力机制来加强特征提取能力,能够高效准确地实时提取滑坡信息。

综合上述研究,虽然深度学习方法取得了较好的结果,但现有的深度学习网络模型通常仅使用单一的遥感影像数据源作为已有滑坡识别的数据,无法从中充分提取到坡度、坡向和高度等地形特征的变化,具有一定的局限性。因此,该文采用多源数据融合的方式,通过融合 DEM^[19]数据,从多角度的方向来识别滑坡,设计一种不共享权重的孪生网络,分别从遥感影像中提取色彩和纹理特征,从 DEM 中提取高度、坡向等地形特征,实现两种不同数据的融合分析。同时,在现有的语义分割模型 DeeplabV3+中,通过引用 SE 注意力机制模块,给每个通道分配不同的权重,从而增强模型对重要特征的关注,以进一步提高模型识别的精度。

1 分析方法

该文使用的深度学习模型融合了孪生网络的结构、MobileNetV2 轻量级网络、DeeplabV3+网络与 SE 注意力机制模块。如图 1 所示,通过设计一种非共享参数的孪生网络从遥感影像和 DEM 数据中提取关于

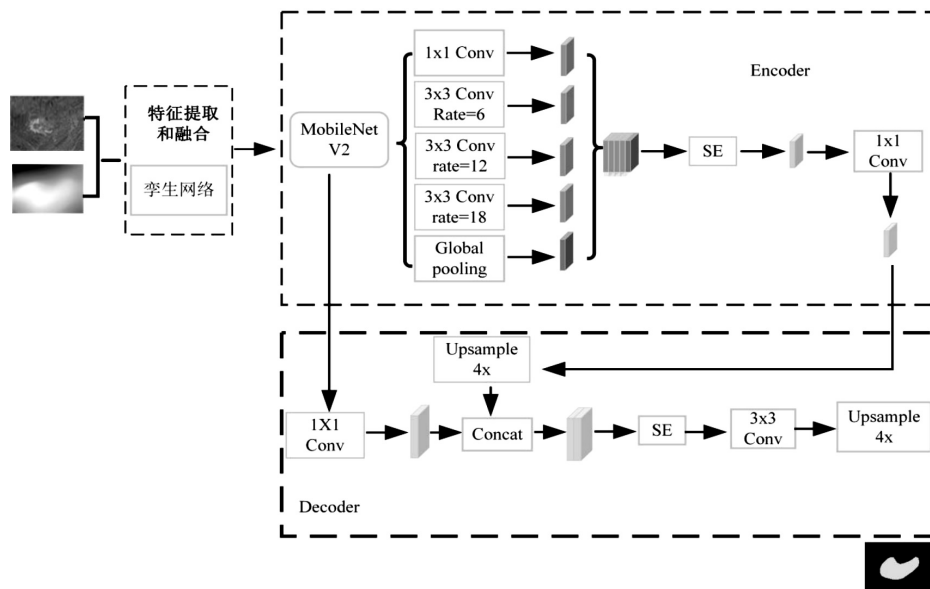


图 1 基于多源数据融合的山体滑坡网络识别模型

滑坡不同维度的信息进行融合,结合卫星遥感图像的颜色纹理信息和 DEM 的地形起伏和高程变化信息,提供更丰富的识别判定标准,减少数据在融合上面造成的信息冗余,从而提高滑坡的识别性能。为进一步增强 ASPP 输出特征的目标信息提取能力和提高滑坡特征细节恢复能力,分别在 ASPP 后面和解码器中深层语义特征与浅层语义特征拼接处加入 SE 注意力机制模块。

基于注意力机制改进的 DeepLabV3+模型由编码器和解码器组成。编码器部分由 MobileNetV2 作为深层语义主干特征提取网络,对融合后的语义特征进行初步提取,可以有效降低计算复杂度,提升模型整体性能。其次进行 ASPP 操作,进一步提取图像全局特征。其中,ASPP 模块通过引入不同的空洞率卷积进行特征提取,从而实现对不同尺度的信息进行捕捉,可以有效捕捉到图像中的多尺度信息。但由于 ASPP 主要关注空间上的多尺度信息,忽略了各个通道之间不同的重要性,故在 ASPP 后加入 SE 注意力机制,在保持原有特征的基础上,通过学习不同通道之间的关系,动态调整不同通道的权重,从而增加重要信息的权重,提高模型对重要信息的关注,抑制不重要的通道。

解码器部分用于恢复图像尺寸,将 ASPP 输出的深层语义特征图与浅层语义特征图进行拼接,为了有效提高滑坡细节的恢复和模型在分割边界和细节部分的表现,加入 SE 注意力机制模块,从而减少冗余和不相关的信息。经过三者的融合,能够显著提高模型的性能和滑坡预测识别的精度。

1.1 特征提取和融合模块

虽然 DeepLabV3+网络模型在语义分割上具有良好的性能,但滑坡通常发生在地形复杂的区域,大部分滑坡区域的特征与背景之间对比不明显,单一的数据源由于信息不完整或噪声问题影响分割结果,而 DEM 数据可以提供地形的高程信息,通过与遥感数据融合,能够帮助模型理解地形的起伏和坡度,获得更加全面的信息。利用该网络单独提取 DEM 的地表形态信息和遥感图像的颜色、表面结构、轮廓信息,最后将提取出来的特征进行逐像素相加,实现特征提取和融合。减少了单一数据源造成的误差,从而增强对滑坡特征的提取能力,提供更加稳定的滑坡监测结果。

该部分是由两个相同架构但参数各自独立的轻量级卷积网络组成,也可称为孪生网络。如图 2 所示,该网络的主干选取的是 EfficientNet 网络模型结构,由卷积核大小为 3×3 的卷积、MBConv 模块和卷积核大小为 1×1 的卷积组成,模块中采用了批标准化和 Swish 激活函数,Swish 激活函数如式 1 所示。

$$f(x) = x \cdot \text{sigmoid}(x) = x \cdot \frac{1}{1 + e^{-x}} \quad (1)$$

其中,MBConv 模块主要是由一个 1×1 的普通卷积(升维作用,包含 BN 和 Swish)、3×3 的深度可分离卷积(Depthwise Conv)、一个 SE 模块、一个 1×1 的普通卷积(降维作用,包含 BN)和一个 Dropout 层组成^[20]。MBConv n 表示该模块中最开始的 1×1 卷积将特征张量的通道数扩展 n 倍,这里仅选用了 n 为 1 和 6 的倍率因子。

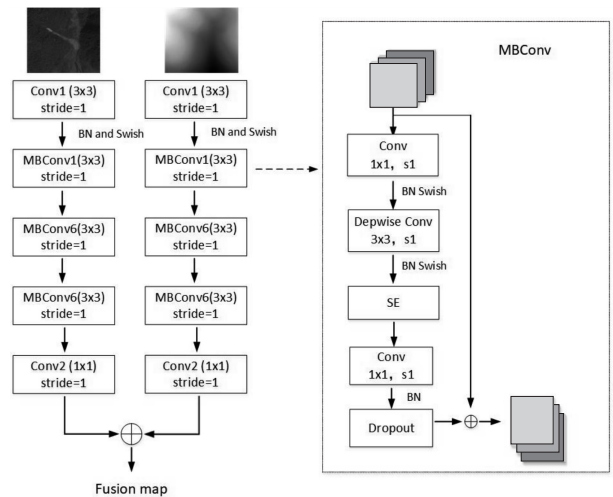


图 2 不共享参数的孪生网络结构

深度可分离卷积(Depthwise Separable Convolution)是由逐深卷积(depthwise)和逐点卷积(pointwise)两部分组成用来提取特征,如图 3 所示。这里的深度可分离卷积选取的是卷积核大小为 3×3 的卷积,其中逐深卷积是在所有输入层的通道上分开应用卷积操作,对输入的每个通道单独提取空间信息,不会改变最终的通道数。逐点卷积是使用大小为 1×1 的卷积核进行卷积操作,通过将所有输入通道的信息进行线性组合来生成输出通道。与其他常规卷积相比,其参数量和运算成本较低,大大减少了计算量,有效提升了整体的计算效率。




图 3 深度可分离卷积

1.2 SE 注意力机制

在解码器和编码器中引入 SE 模块可以使模型在训练过程中自动调整不同通道的权重分配,进一步增强滑坡的识别性能。SE 模块如图 4 所示,该模块主要由 Squeeze 和 Excitation 两个操作组成,Squeeze 是根据特征图的高度和宽度进行全局平均池化操作将输入

特征图压缩成一个向量,通过一个全连接层将其映射到一个较小的向量^[21]。

Squeeze 操作定义如下:

$$z = F_{sq}(U_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (2)$$

其中, u_c 为特征通道为 c 的特征图, H 和 W 分别为特征图的高度和宽度。Excitation 操作通过为每个特征通道生成权重,再使用一个 sigmoid 函数将这个向量中的每个元素压缩到 0 和 1 之间,并将其与原始输入特征图进行相乘。Excitation 操作定义如下:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 \times z)) \quad (3)$$

其中, $W(W_1, W_2)$ 为全连接层的参数, δ 为 ReLU 激活函数, σ 为 sigmoid 激活函数。使用 sigmoid 激活函数得到的归一化值对原始信道进行加权,进行特征权值的计算,进而对特征图 U 进行权重赋值,得到最终的特征图 \tilde{x} 。

$$\tilde{X} = F_{scale}(U_c, s) = U_c \times s \quad (4)$$




图4 Squeeze-and-Excitation 模块结构

2 数据集及实验设置

2.1 数据介绍及预处理

该文使用毕节滑坡公开数据集作为实验数据来验证模型的泛化性。研究区域覆盖毕节市全境,面积约 26 853 km²,位于中国贵州省西北部,海拔 457 ~ 2 900 m,地质不稳定,山坡多,雨量丰富,敏感的生态条件是该地区成为我国滑坡较严峻区域的原因。采集数据的时间为 2018 年 5 月到 8 月,由 TripleSat(北京二号)卫星采集,该数据集由卫星光学图像、滑坡边界形状和数字高程模型组成,影像分辨率 0.8 m,DEM 的高程精度为 2 m,其中有 770 个滑坡样本和 2 003 个非滑坡样本。

在实验数据集中,由于滑坡规模大小有一定差别不能直接用作训练数据,故在保持滑坡样本长宽比的情况下,通过调整尺寸将图片大小统一调整为 224 × 224。同时,为了避免数据量过少导致模型在训练过程中出现过拟合的现象,使用水平和垂直翻转、旋转、平移等数据增强的方式对数据进行了一定的扩充,在训练过程中对增强后的数据进行随机打乱,其中选取总样本中的 80% 用于模型的训练,20% 用于验证和测试。

2.2 实验设置

实验环境使用的操作系统为 Windows10,使用 Py-torch 框架来搭建模型,在 kaggle 平台上进行模型训练,模型训练选用随机梯度下降(Stochastic Gradient Descent,SGD)作为优化器,其中动量设置为 0.9,权重衰减设置为 0.000 5,所有实验都采取 0.001 的学习率,batch size 设置为 16,最大迭代次数为 100。

模型训练使用交叉熵作为损失函数,如式 5 所示。

$$\text{Loss} = -\frac{1}{N} \times \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (5)$$

其中,目标像素标记为 1,背景像素标记为 0。 y_i 为真实标签, \hat{y}_i 为预测标签。

2.3 评估指标

实验采用精确率(Precision)、召回率(Recall)、F1 分数(F1-score)、MIoU(平均交并比)作为分割结果的评估指标^[22]。其中 F1-score 是精确率和召回率的加权调和平均,F1-score 值越接近 1,则模型在查全率和查准率两方面的综合表现越好。MIoU 用于衡量分割任务中预测结果与真实标签之间的相似程度,通过计算预测结果与真实标签之间的重叠区域与它们的并集之间的比例来度量它们的相似程度。

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

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

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

$$\text{MIoU} = \frac{1}{2} \times \left(\frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} + \frac{\text{TN}}{\text{TN} + \text{FN} + \text{FP}} \right) \quad (9)$$

其中,TP 表示被正确预测为滑坡像素点的数量,FP 表示被错误预测为滑坡像素点的数量,FN 表示被错误预测为非滑坡像素点的数量,TN 表示被正确预测为非滑坡像素点的数量。实验主要关注 F1-score 和 MIoU 两个衡量指标。

3 实验结果及分析

该文使用毕节市滑坡数据集作为语义分割的数据集,训练数据、验证数据和测试数据按照 8 : 1 : 1 的形式划分,长宽大小为 224 × 224。使用特征提取和融合网络对光学遥感影像和 DEM 数据分别进行特征提取,将提取出来的语义特征进行融合,融合后的数据输入到语义分割模型中进行训练,训练模型是引入 SE 注意力机制并以 MobileNetV2 为骨干网络的 Deep-LabV3+模型。

3.1 消融实验

在毕节市滑坡数据集上的实验评价结果如表 1 所示,测试了三种数据利用方案:仅用光学遥感影像 (RGB)、仅用 DEM 数据、遥感影像与 DEM 特征融合数据 (RGB+DEM)。实验结果表明,遥感影像数据与 DEM 两种异质数据的融合相较于单一数据在滑坡识

别上的精度有较大的提升。其中 F1 分数和 MIoU 比仅使用遥感图像分别高 5.8 个百分点和 4.2 百分点,只使用数字高程模型 (DEM) 的检测结果较差,无法精确对滑坡进行识别,单独的遥感图像数据在识别时的效果要比 DEM 数据好,说明在滑坡检测过程中具有重要的作用。

表 1 消融实验

数据输入方式	精确率	召回率	F1 分数	平均交并比
RGB	0.738	0.729	0.733	0.779
DEM	0.524	0.526	0.525	0.665
RGB+DEM	0.781	0.792	0.791	0.821

3.2 融合方式对比

在与通道融合 (RGB+DEM 四通道)、不使用特征提取和融合网络的情况下直接将光学遥感影像和 DEM 数据通过逐像素相加的方式进行对比。如表 2

所示,实验结果表明使用了特征提取和融合网络的数据融合方式在准确率、召回率、F1 分数、平均交并比的评估指标下均优于其他两种融合方式。

表 2 不同数据融合方式的实验对比

数据融合方式	精确率	召回率	F1 分数	平均交并比
通道融合	0.731	0.724	0.728	0.778
直接逐像素相加	0.746	0.749	0.747	0.791
特征融合	0.781	0.792	0.791	0.821

直接逐像素相加的方式要优于通道融合的方式,将遥感影像和 DEM 数据进行通道融合时,虽然保留了数据的独立性,但由于通道之间的权重存在分配不均衡的问题,使得模型需要更多的参数和计算来有效学习不同通道间的关系,因此无法充分利用高度信息进行准确的分割。

非线性关系和空间依赖。

而该文设计的特征提取和融合网络能够自动地从数据中学习多层次的特征表达,尤其是高层次的遥感影像特征 (如纹理、形状、色彩等) 和 DEM 特征 (坡度、坡向、高程等),相比于直接逐像素相加的融合方式, CNN 可以更好地捕捉遥感影像和 DEM 数据中的复杂

不同数据输入方式的测试分割效果如图 5 所示,其中 a、b、c、d 分别表示仅用遥感图像、通道融合、直接逐像素相加、使用该文设计的孪生网络进行特征融合。训练和测试模型选用的是引入 SE 注意力机制模块改进的 DeepLabV3+ 模型。通过对比单一数据源 (仅使用遥感影像)、通道融合、直接逐像素相加的分割结果,可以看出该文设计的通过不共享权重的孪生网络进行滑坡数据特征提取和融合方式相比于其他方式可以获得更精确的滑坡边缘分割效果,可以更好地排除非滑坡像素,减少误判区域。

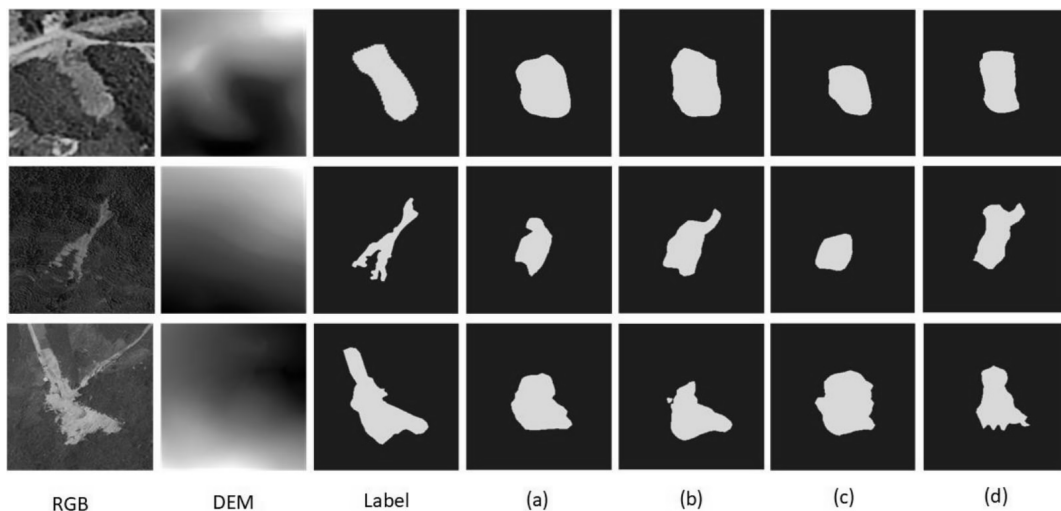


图 5 不同融合方式滑坡分割结果对比

3.3 网络模型对比

通过与语义分割模型 U-Net、FCN、SegNet、AED-Net^[15] 和 DeepLabV3+ 进行对比,在模型验证过程中,所有实验均在同等参数的设置下分别进行训练,在测试数据集上进行滑坡识别。如表 3 所示,实验分割结果表明提出的基于注意力机制改进的 DeepLabV3+ 模型在 F1-score 和 MIoU 评估指标上分别达到了 0.791 和 0.821,与原模型 DeepLabV3+ 相比分别提高 1.6 个百分点和 1.1 百分点。由于 U-Net^[23] 没有使用空洞卷积和多尺度的特征提取,因此在处理复杂场景时,全局上下文信息捕获能力较弱;FCN^[24] 主要依赖反卷积层进行上采样操作,容易导致边界模糊和细节丢失,难以有效捕获多尺度的上下文信息;SegNet^[25] 在解码器部分通过池化索引进行上采样,没有充分结合浅层特征和深层特征,在细节恢复上存在着一定的不足;因此 U-Net、FCN 和 SegNet 模型在滑坡识别效果上不如 DeepLabV3+ 模型。而 AED-Net^[15] 通过减少 ASPP 模块中膨胀卷积的膨胀率,使得卷积的感受野变小,从而更关注局部区域的细节,提升对局部纹理的表达力。同时,加入通道注意力机制模块来提高通道特征选择能力,使得对滑坡的识别效果要优于 DeepLabV3+ 模型。但是通道注意力机制无法更加灵活地进行通道权重的调整且更关注通道间的局部关系,虽然高效,但缺乏全局视角的建模能力。而融入 SE 注意力机制可以帮助模型更好地关注关键特征,更全面、灵活地捕获每个通道在整个特征图上的全局重要性,适合处理复杂的大尺度变化的滑坡任务,提高在复杂背景下的分割精度,更加适合于本实验在对数据进行特征提取和融合的基础上应用 DeepLabV3+ 这种复杂的分割网络,从而在滑坡准确识别方面表现更为优越。

表 3 不同网络模型的实验对比

网络模型	精确率	召回率	F1 分数	平均交并比
U-Net	0.621	0.651	0.634	0.724
FCN	0.651	0.632	0.641	0.729
SegNet	0.613	0.619	0.616	0.714
AED-Net	0.776	0.775	0.778	0.811
DeeplabV3+	0.772	0.778	0.775	0.810
SE+DeepLabV3+	0.781	0.792	0.791	0.821

根据以上语义分割网络模型的滑坡评估指标来看,提出的通过引入 SE 模块的改进 DeepLabV3+ 模型,相比于其他语义分割模型在评估指标和检测效果上都有明显的提升。

4 结束语

针对单一数据源在滑坡识别上存在信息不完备、

难以捕捉滑坡复杂特征以及识别精度不足的问题,提出了一种基于孪生网络特征提取和融合模块的注意力机制改进的 DeepLabV3+ 语义分割模型。该模型通过在语义分割模型之前使用基于孪生网络的特征提取和融合模块对两种异质数据进行特征提取和融合,通过融合这两类数据,可以实现信息互补,结合地表特征和地形特征,提升滑坡识别的精度和鲁棒性。将融合后的特征输入到引入 SE 注意力机制模块的语义分割网络进行滑坡识别,SE 注意力机制可以自适应地调整各个通道的权重,强化重要的特征通道,抑制不重要的通道,有助于突出显示对细节恢复有帮助的特征,从而提升模型准确恢复分割边界形状和细节部分的效果。

在毕节市滑坡数据集上进行实验,经过对比、消融实验表明,提出的多源数据融合模型相较于单一数据源、其他融合方式以及 Unet、FCN、SegNet 语义分割模型有着更精确、更完整的分割效果,且相对于原模型 MIoU 提升 1.1 百分点。虽然在多源数据融合的基础上引入 SE 注意力机制的 DeepLabV3+ 模型在滑坡识别精度上有了显著的提高,但由于存在多种的融合策略,从中找到最优方案需要较多的时间,因此未来的研究应重点探索更优的融合方法。

参考文献:

- [1] 陈景松. 基于风险管控的滑坡治理措施研究[D]. 武汉: 武汉大学, 2023.
- [2] 佟素娟, 薛同来, 王宿仲, 等. 无线传感器网络在现代环境监测中的应用[J]. 工业控制计算机, 2023, 36(12): 116-117.
- [3] 任贵文, 温经林, 黄全荣, 等. 多源遥感技术在滑坡灾害应急救援中的应用[J]. 中国安全生产科学技术, 2022, 18(S1): 31-36.
- [4] 汪伦. 基于 InSAR 与深度学习的滑坡监测研究[D]. 长春: 长春工程学院, 2023.
- [5] 马旭东. LiDAR 技术在九寨沟滑坡地质灾害识别及易发性评价中的应用[D]. 重庆: 西南科技大学, 2023.
- [6] LIU Z, MA J, XIA D, et al. Toward the reliable prediction of reservoir landslide displacement using earthworm optimization algorithm-optimized support vector regression (EOA-SVR)[J]. Natural Hazards, 2024, 120(4): 3165-3188.
- [7] XING X, WU C, LI J, et al. Susceptibility assessment for rainfall-induced landslides using a revised logistic regression method[J]. Natural Hazards, 2021, 106: 97-117.
- [8] ZHANG Y, TANG J, CHENG Y, et al. Prediction of landslide displacement with dynamic features using intelligent approaches[J]. International Journal of Mining Science and Technology, 2022, 32(3): 539-549.
- [9] WU X, SONG Y, CHEN W, et al. Analysis of geological hazard susceptibility of landslides in multi county based on

- random forest algorithm [J]. *Sustainability*, 2023, 15 (5): 4328.
- [10] XU J, JIANG Y, YANG C. Landslide displacement prediction during the sliding process using XGBoost, SVR and RNNs [J]. *Applied Sciences*, 2022, 12 (12): 6056.
- [11] WU Y F, A F Y, YANG C, et al. Accuracy improvement of different landslide susceptibility evaluation models through k-means clustering: a case study on China's funing county [J]. *Mathematical Problems in Engineering*, 2023, 2023 (1): 2913890.
- [12] NAVA L, CARRARO E, REYES-CARMONA C, et al. Landslide displacement forecasting using deeplearning and monitoring data across selected sites [J]. *Landslides*, 2023, 20 (10): 2111-2129.
- [13] HUSSAIN M A, CHEN Z, ZHENG Y, et al. Deep learning and machine learning models for landslide susceptibility mapping with remote sensing data [J]. *Remote Sensing*, 2023, 15 (19): 4703.
- [14] CHEN T. BisDeNet: A new lightweight deep learning-based framework for efficient landslide detection [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 3648-3663.
- [15] 蒋伟杰, 张春菊, 徐兵, 等. AED-Net: 滑坡灾害遥感影像语义分割模型 [J]. *地球信息科学学报*, 2023, 25 (10): 2012-2025.
- [16] HE Y, WANG W, ZHANG L, et al. An identification method of potential landslide zones using InSAR data and landslide susceptibility [J]. *Geomatics, Natural Hazards and Risk*, 2023, 14 (1): 2185120.
- [17] LV P, MA L, LI Q, et al. ShapeFormer: a shape-enhanced vision transformer model for optical remote sensing image landslide detection [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 2681-2689.
- [18] ZHOU N, HONG J, CUI W, et al. A multiscale attention segment network-based semantic segmentation model for landslide remote sensing images [J]. *Remote Sensing*, 2024, 16 (10): 1712.
- [19] OKOLIE C J, SMIT J L. A systematic review and meta-analysis of digital elevation model (DEM) fusion: pre-processing, methods and applications [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 188: 1-29.
- [20] 徐天伦, 李波, 胡文杰, 等. 基于 CA-EfficientDet 的棉布瑕疵检测方法 [J]. *中南民族大学学报: 自然科学版*, 2022, 41 (2): 243-250.
- [21] 南国君, 王敏, 都海波, 等. 基于改进 Deeplabv3+ 模型的遥感影像地物语义分割方法研究 [J/OL]. *控制与决策* [2024-09-09].
- [22] 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.
- [23] AL QURRI A, ALMEKKAWY M. Improved UNet with attention for medical image segmentation [J]. *Sensors*, 2023, 23 (20): 8589.
- [24] ZHAO H, LIANG M, LI H. Research on gesture segmentation method based on FCN combined with CBAM-ResNet50 [J]. *Signal, Image and Video Processing*, 2024, 18: 7729-7740.
- [25] GUPTA D. Image segmentation keras: implementation of segnet, fcn, unet, pspnet and other models in keras [J]. *arXiv*: 2307.13215, 2023.