



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目：一种识别植被覆盖滑坡的多模态深度神经网络模型
作者：唐小川，涂子涵，任绪清，方成勇，王宇，刘鑫，范宣梅
DOI：10.13203/j.whugis20230099
收稿日期：2023-03-23
网络首发日期：2023-08-30
引用格式：唐小川，涂子涵，任绪清，方成勇，王宇，刘鑫，范宣梅. 一种识别植被覆盖滑坡的多模态深度神经网络模型[J/OL]. 武汉大学学报(信息科学版).
<https://doi.org/10.13203/j.whugis20230099>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20230099

引用格式：唐小川, 涂子涵, 任绪清, 等. 一种识别植被覆盖滑坡的多模态深度神经网络模型[J]. 武汉大学学报(信息科学版), 2023, DOI:10.13203/J.whugis20230099 (TANG Xiaochuan, TU Zihan, REN Xuqing, et al. A Multi-Modal Deep Neural Network Model for Forested Landslide Detection[J]. Geomatics and Information Science of Wuhan University, 2023, DOI:10.13203/J.whugis20230099

一种识别植被覆盖滑坡的多模态深度神经网络模型

唐小川^{1,2,3,4} 涂子涵¹ 任绪清¹ 方成勇² 王宇¹ 刘鑫¹ 范宣梅²

¹ 成都理工大学计算机与网络安全学院, 四川 成都, 610059

² 成都理工大学地质灾害防治与地质环境保护国家重点实验室, 四川 成都, 610059

³ 中国民用航空飞行学院民航飞行技术与飞行安全重点实验室, 四川 德阳, 618307

⁴ 电子科技大学通信抗干扰技术国家级重点实验室, 四川 成都, 611731

摘要: 我国西南山区植被茂盛, 该区域光学遥感影像上的滑坡常被植被遮挡、难以辨识, 基于光学遥感影像的植被覆盖滑坡识别错误率较高, 难以满足实际需求。针对这一问题, 利用机载激光雷达(light detection and ranging, LiDAR)生成的数字高程模型(digital elevation model, DEM)和山体阴影图去除滑坡表面的植被覆盖, 构建了一个植被覆盖山区的滑坡数据集。在此基础上, 提出一种基于多模态深度学习的智能滑坡识别模型, 综合利用 DEM 和山体阴影图识别植被覆盖条件下的滑坡, 模型主要包括三个神经网络模块: 自动提取 DEM 数据特征的 Transformer 神经网络, 自动提取山影图特征的 Transformer 神经网络, 以及融合多模态遥感数据的卷积注意力神经网络。通过实验对比了 ResU-Net、LandsNet、HRNet、SeaFormer 模型, 实验结果表明, 所提出的模型达到了最高的滑坡预测精度, IoU 和 F1 分别提高了 9.3% 和 6.8%。因此, LiDAR 能够有效地去除植被干扰, 适用于识别西南山区植被覆盖条件下的滑坡; 本文提出的 LiDAR 滑坡识别模型能够预测滑坡的位置, 为滑坡监测设备选址提供有力支撑。

关键词: 滑坡识别; 植被覆盖; 山体阴影图; DEM; 多模态深度学习; 数据融合

A Multi-Modal Deep Neural Network Model for Forested Landslide Detection

TANG Xiaochuan^{1,2,3,4} TU Zihan¹ REN Xuqing¹ FANG Chengyong² WANG Yu¹
LIU Xin¹ FAN Xuanmei²

¹ College of Computer Science and Cyber Security, Chengdu University of Technology, Chengdu 610059, China

² State Key Laboratory of Geohazard Prevention and Geoenvironment Protection, Chengdu University of Technology, Chengdu 610059, China

³ Key Laboratory of Flight Techniques and Flight Safety, Civil Aviation Flight University of China, Deyang 618307, China

⁴ National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China

Abstract: Objectives: Vegetation widely spread in the southwestern mountainous regions of China. In the remote sensing images of this area, the landslides are usually shaded by vegetation. The error rate of forested landslide detection in remote sensing images is high, which is hard to meet practical needs. **Methods:** To address this issue, this article uses light detection and ranging (LiDAR)-derived digital elevation mode (DEM) and Hillshade to remove the forest on the landslides. In addition, a new dataset for forested landslide detection is also constructed. On this basis, an intelligent landslide detection model base on multimodal deep learning is proposed. The proposed model

收稿日期: 2023-03-23

项目资助: 中国博士后科学基金(2021M690024); 民航飞行技术与飞行安全重点实验室开放项目资助(FZ2022KF13)。

第一作者: 唐小川, 博士, 副教授, 主要从事人工智能与地质灾害监测预警研究。xc.tang@qq.com

通信作者: 范宣梅, 博士, 研究员。fxm_cdut@qq.com

uses DEM and hillshade to identify forested landslides, which consists of three neural network models. First, a Transformer network for automatic extraction of DEM features is proposed. Second, a Transformer network for automatically extracting hillshade features is proposed. Third, a convolution neural network with attention mechanism for merging multimodal remote sensing data is proposed. **Results.** The proposed model is compared with ResU-Net, LandsNet, HRNet and SeaFormer. Experimental results show that the proposed model achieves the highest prediction accuracy. IoU and F1 is improved by 9.3% and 6.8%. **Conclusions.** LiDAR is able to remove the impact of forest cover, which is suitable for identifying the forested landslides in the southwest mountain areas of China. The proposed LiDAR-based landslide detection model is able to predict the position of landslides, which is useful for deciding the position of landslide monitoring devices.

Keywords: landslide detection; vegetation cover; hillshade; DEM; multi-modal deep learning; data fusion

我国滑坡灾害多发频发且常被植被覆盖,为滑坡防治带来了巨大的挑战。通过多轮地质灾害调查,已经发现了 30 多万处滑坡隐患点,但是近年来 80%的地质灾害未发生在隐患点范围内,可见仍有许多滑坡隐患点尚未被发现^[1]。现有的滑坡识别方法难以识别高山峡谷区植被覆盖下的滑坡,植被覆盖导致光学影像上的滑坡特征不明显^[2],同时也对基于合成孔径雷达干涉测量(synthetic aperture radar interferometry, InSAR)的形变监测造成干扰^[3],传统的滑坡识别方法面临巨大挑战。机载遥感监测技术具有响应速度快、分辨率高、覆盖面积大的优势,其中机载 LiDAR^[4-6]还能捕获高分辨率、高精度的高程信息,通过 LiDAR 点云能够有效去除植被并且获取植被覆盖下的真实地表信息,为破解植被覆盖区的滑坡识别问题提供了新的研究思路。

基于 LiDAR 的植被覆盖区滑坡识别方法主要包括人工解译方法和自动识别方法。人工解译通常由经验丰富的地质专家进行^[7-8],滑坡识别精度高,但效率低,难以满足海量遥感数据分析的需求。自动识别方法的效率高,可分为深度学习和非深度学习方法。非深度学习方法主要从 LiDAR 生成的 DEM 中提取的坡度、坡向和高程等特征因子,并结合机器学习的分类器进行滑坡识别,例如随机森林、支持向量机和人工神经网络^[9-14]。深度学习方法能够从遥感数据中自动提取特征,能够弥补非深度学习方法在人工特征提取阶段遗漏的关键特征因子^[15]。当前基于深度学习的滑坡识别方法主要使用卷积神经网络^[16-18],存在感受野小的问题。现有自动滑坡识别的研究对象主要是光谱和纹理特征明显的新滑坡,例如:同震滑坡^[19-23]和降雨型滑坡^[24],关于植被覆盖区古老滑坡识别的研究尚处于起步阶段^[25]。此外,许多自动识别方法仅使用单一类型的遥感数据源,未能充分利用多源遥感数据的互补信息,导致滑坡识别精度不高、鲁棒性不强^[25]。

针对植被覆盖山区的滑坡识别问题,本文的目标是建立一种抗植被干扰的新型滑坡识别模型,主要创新点体现在以下三个方面:第一,提出一种自动识别植被覆盖滑坡的多模态深度神经网络模型(multi-modal landslide detection, MMLD);第二,提出一种基于 Transformer 和形变卷积神经网络的遥感数据特征提取方法;第三,提出利用 LiDAR 生成的 DEM 和山影图数据训练滑坡识别模型。同时,本文还建立了植被覆盖山区滑坡数据集,并利用该数据集验证了 MMLD 模型的先进性和有效性。

1 研究区与数据源

1.1 研究区概况

本文的研究区域为 8·8 九寨沟地震震区,位于四川省西北部岷山山脉南段的阿坝藏族羌族自治州九寨沟县,该区域地形地貌复杂、植被茂盛、滑坡发育,新滑坡和古老滑坡分布广泛。为了建立植被覆盖滑坡识别模型,邀请经验丰富的地质专家标注了研究区域的植被覆盖

滑坡，共识别 1758 处滑坡，主要分布于地质断层、河谷、道路附近。

为了准确评估滑坡识别模型的性能，将研究区域划分为两个相互独立的区域，如图 1 所示，左方黄色多边形内的区域为测试区域，其余部分为训练区域。

1.2 数据源

本文收集了九寨沟震区的 LiDAR 点云数据并进行了预处理，方法如下：

首先，利用 Global Mapper 软件从原始 LiDAR 点云中构建 DEM，分辨率为 0.5 m，如图 1(a)所示。DEM 反映出真实地表的高程信息，通过 DEM 可以构建研究区域的地表三维模型，进而从三维空间中提取丰富的几何特征，例如点、线、面、方向、斜率和曲率等。

其次，利用 Global Mapper 软件从原始 LiDAR 点云中构建山体阴影图，如图 1(b)所示，其中光源数为 12，垂直比例因子为 1，太阳方位角为 30°。山体阴影图是指利用计算机模拟太阳光源照射山体，计算每个像元的光照强度，显著地增强了 DEM 中地形地貌的可视化效果。山体阴影图能够体现出研究区域的地表细节，反映出植被覆盖下的滑坡纹理和边界等特征^[26-27]。

最后，研究区域的遥感数据尺寸太大，不能直接用于构建深度学习模型，需要进行裁剪。裁剪后的遥感数据块的尺寸为 1024×1024。最终得到训练集和测试集的样本数分别为 1446 和 324，两者的比例约为 8:2。

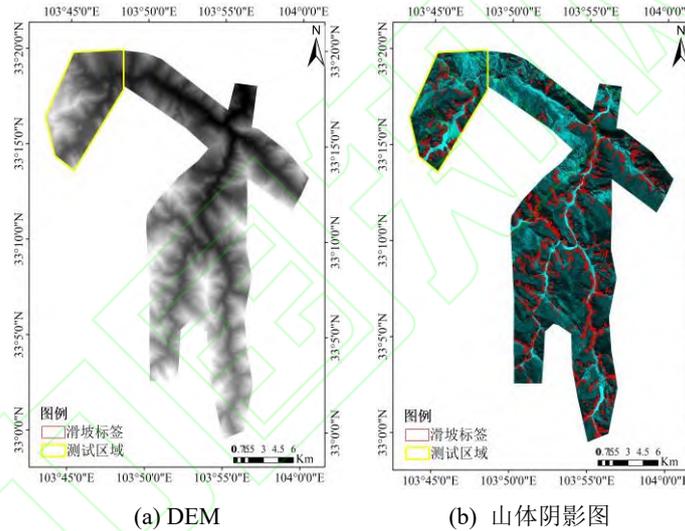


图 1 九寨沟震区的 DEM 和山体阴影图

Fig.1 DEM and Hillshade of the Jiuzhaigou earthquake area

2 多模态深度神经网络模型

植被覆盖导致滑坡在光学遥感影像上难以被有效识别，本文提出一种基于 LiDAR 的多模态深度神经网络的滑坡识别模型(MMLD)，模型的整体结构如图 2 所示。该模型的输入是 LiDAR 点云生成的 DEM 和山体阴影图，由编码器模块、DEM 特征提取模块、多模态遥感数据融合模块和解码器模块四部分组成。步骤为：(1)建立 DEM 特征提取模块，自动提取 DEM 数据的特征。(2)建立编码器模块，自动提取山体阴影图的特征。(3)建立数据融合模块，融合 DEM 和山体阴影图的特征。(4)建立解码器模块，利用多模态特征进行滑坡预测。

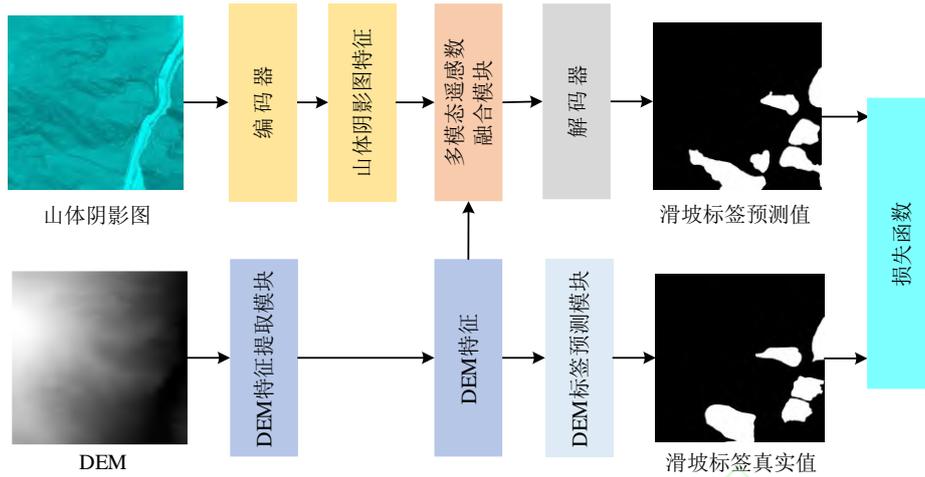


图 2 MMLD 模型的网络结构图

Fig.2 The network structure of the proposed model MMLD

2.1 DEM 特征提取模块

DEM 含有丰富的三维空间特征，本文提出一种自动提取 DEM 特征的深度神经网络模块(图 3 上半部分)，利用 Transformer 学习 DEM 特征图的全局依赖性，同时利用 HRNet 神经网络架构^[28]保持高分辨率。主要包括 3 个神经网络分支，分别用于学习高、中和低分辨率的特征。第 1 个分支由 3 个 Transformer 和 1 个形变卷积组成，得到的特征图尺寸为 $1024 \times 1204 \times 64$ ，有效地保留了原始 DEM 的高分辨率；第 2 个分支由 2 个 Transformer 和 1 个形变卷积组成，得到的特征图尺寸为 $256 \times 256 \times 128$ ；第 3 个分支有 1 个 Transformer 和 1 个形变卷积组成，得到的特征图尺寸为 $64 \times 64 \times 256$ 。第 2 和第 3 个分支的特征图分辨率有所降低，但每次卷积操作能够覆盖更大的地理范围。形变卷积支持构建不规则的感受野。标准卷积的感受野是一个矩形区域，本文针对自然地物的不规则性提出利用形变卷积构建不规则的感受野^[29]。如图 4 所示，形变卷积的原理是通过引入可学习的形变参数来对传统卷积操作进行改进，具体实现可分为两个步骤：①在输入特征图上以卷积核中心作为参考点，然后利用一个额外的卷积层学习偏移量，这些偏移量用于调整采样点的位置，从而生成一个形变后的采样点网格；②在形变后的采样点网格上，对输入特征图进行插值，获取对应采样点的特征值，即可得到形变后的输出特征图。形变卷积使得卷积核的位置和形状能够根据输入特征图的内容自适应地进行调整，从而更好地捕捉目标的形变信息。

DEM 预测模块以形变卷积层输出的特征图作为输入，以山体阴影图作为标签，利用一个 3×3 卷积和一个 1×1 卷积建立分类器，预测标签。该方法的优势在于将地灾知识融入到深度学习模型，即利用 DEM 生成的山体阴影图作为标签，引导深度学习自动学习 DEM 的三维空间几何特征，避免人工标注 DEM 数据的巨大开销。山体阴影图是关于坡度、坡向和光照的函数，如果 DEM 特征提取模块能够较为准确地预测山体阴影图，那么自动提取的特征集中必然包含坡度和坡向等 DEM 几何特征。

DEM 特征提取模块的损失函数为均方误差函数。DEM 的标签为山体阴影图，记为 Y_{DEM} 。设 DEM 预测模块的输出为 \hat{Y}_{DEM} 。则 DEM 特征提取模块的损失函数为 Y_{DEM} 与 \hat{Y}_{DEM} 之间的均方误差。

$$L_{\text{DEM}} = \frac{1}{N} \sum_{i=1}^H \sum_{j=1}^W (\hat{Y}_{\text{DEM}}(i, j) - Y_{\text{DEM}}(i, j))^2 \quad (1)$$

2.2 山体阴影图特征提取模块

山体阴影图特征提取模块采用编码器-解码器模块结构，如图 3 的下半部分所示。编码

器模块利用 SeaFormer^[30]模块提取山体阴影图的多尺度特征，形成包含 3 个不同分辨率的特征金字塔，分辨率与 § 2.1 的 DEM 特征保持一致。不同尺度的特征有助于识别不同大小的滑坡。SeaFormer 模块是一种轻量化的 Transformer，通过减少自注意力机制的计算量达到提升 Transformer 计算效率的目标。

解码器模块的输入是利用 § 2.3 的多模态遥感特征融合模块整合的 DEM 特征和山体阴影图特征。从低分辨率的特征图开始，使用 3×3 卷积进行特征变换，然后使用上采样操作提升分辨率，并与下一个更高分辨率的特征图进行拼接，最终将不同分辨率的特征图聚合为一个高分辨率特征图。再利用一个 3×3 卷积和一个 1×1 卷积建立像素级分类器，进行滑坡预测。

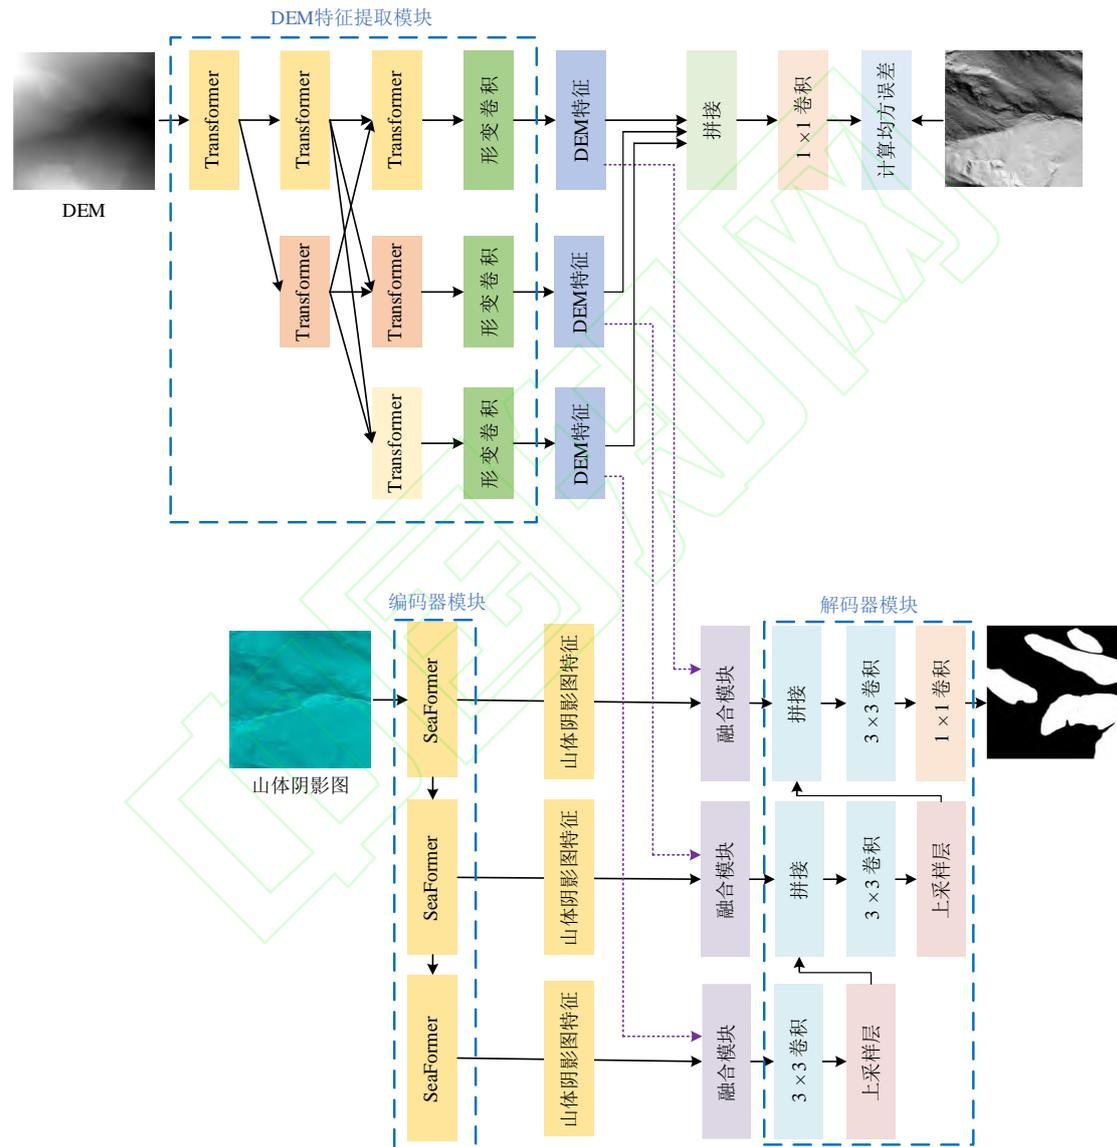


图 3 DEM 和山体阴影图的特征提取模块结构（上半部分表示 DEM 提取模块，下半部分表示山体阴影图特征提取模块）

Fig.3 The structure of the feature extraction model for DEM and Hillshade (The upper graph represents DEM feature extraction model. The lower graph represents Hillshade feature extraction model)

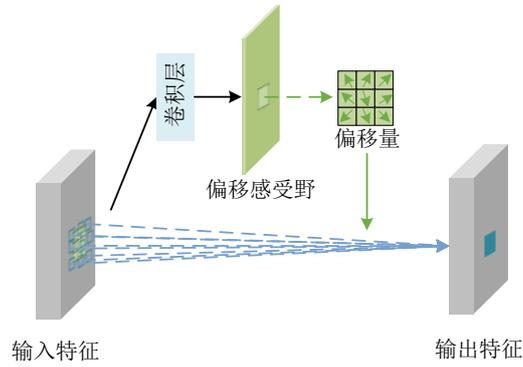


图 4 形变卷积结构图

Fig.4 The structure of deformation convolution

2.3 多模态遥感数据融合模块

通过耦合 DEM 与山体阴影图可以构建去除植被的三维地表模型，如图 5 所示。其中，山体阴影图提供二维地表纹理信息，DEM 提供高程信息，即第三维。为了有机地融合 DEM 与山体阴影图，提出一种多模态遥感数据融合神经网络模块，如图 6 所示。

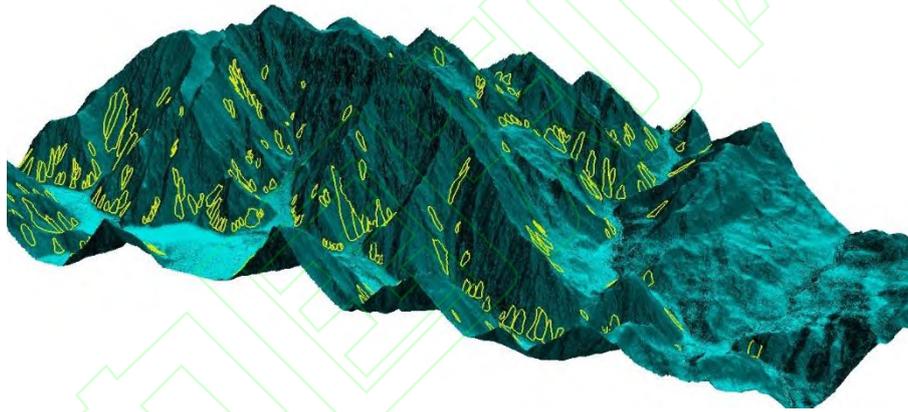


图 5 耦合 DEM 和 Hillshade 形成的三维空间示意图

Fig.5 An example of the 3D space formed by DEM and Hillshade

利用通道注意力机制的作用是从自动提取的特征图中自适应地选择关键图层，实现方法如下：将山体阴影和 DEM 的特征图按通道维度进行拼接；利用平均池化操作计算各个通道的相关性权重，关联性越强的图层权重越大，关联性越弱的图层权重越小；通过矩阵数乘操作作为各个特征图层赋予通道相关性权重。

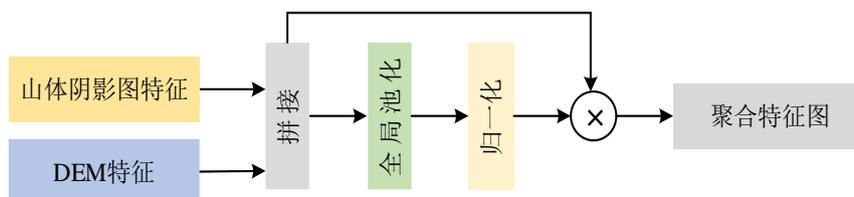


图 6 多模态融合模块

Fig.6 The structure of multi-modal remote sensing data fusion model

滑坡分类的损失函数为交叉熵函数。记解码器的输出为 \hat{Y}_{cls} ，坡分类的损失函数为 \hat{Y}_{cls} 与滑坡标签 Y_{cls} 的交叉熵，公式如下：

$$L_{\text{cls}} = -\frac{1}{N} \sum_{i=1}^H \sum_{j=1}^W Y_{\text{cls}}(i,j) \log \left(\sigma \left(\hat{Y}_{\text{cls}}(i,j) \right) \right) \quad (2)$$

其中, N 为样本数量; σ 为 softmax 激活函数。

MMLD 模型的总损失 L 为 DEM 几何特征提取阶段的损失与滑坡预测阶段的损失之和, 公式如下:

$$L = L_{\text{cls}} + \alpha L_{\text{DEM}} \quad (3)$$

2.4 实验配置与评价指标

实验的硬件设备是一台深度学习云服务器, 含有一块 NVIDIA Tesla V100 40 GB GPU, 一颗 Intel (R) Xeon (R) Gold 6148 CPU。对比模型是使用广泛的语义分割模型, 包括 HRNe^[28] 和 SeaForme^[30], 以及滑坡识别模型 ResU-Net^[31]和 LandsNet^[32]。输入图像的尺寸为 1024×1024, 批量大小为 2, 最大迭代次数为 10000, 损失函数中的 α 取值为 0.001。优化算法为 AdamW, 其权重衰减系数为 0.01, 学习率初始化为 0.00025, 如果损失增加, 学习率以 0.9 因子倍数下降直至为 0。MMLD 和对比模型均在开源深度学习框架 PaddleSeg 中实现。

语义分割模型的性能比较指标包括常用的交并比(intersection over union, IoU)、准确率 (P)、召回率 (R) 和 $F1$ 值^[19], 公式如下:

$$\begin{aligned} \text{IoU} &= \frac{T_P}{F_N + F_P + T_P} \\ P &= \frac{T_P}{T_P + F_P} \\ R &= \frac{T_P}{T_P + F_N} \\ F1 &= \frac{2PR}{P + R} \end{aligned} \quad (4)$$

其中 T_P 、 F_P 、 T_N 、 F_N 分别为真正例(True Positive)、假正例(False Positive)、真反例(True Negative)、假反例(False Negation), 可以通过混淆矩阵计算。上述所有指标值越高, 表示模型预测的准确性越高。

3 实验结果与分析

本文通过详细的实验分析 MMLD 模型的滑坡识别性能以及 DEM 特征提取模块的有效性, 下面详细描述本文的实验配置和实验结果。

3.1 DEM 特征提取模块的有效性

利用 DEM 特征提取模块输出的特征图预测坡度和坡向等典型的滑坡识别特征, 得到的最小均方误差为 0.27 和 0.45, 表明 DEM 特征提取模块有效地提取了滑坡识别特征。图 7(a)-7(f)进一步展示了 DEM、山影图真实值和山影图预测值的可视化结果。可见, 山体阴影图的真实值与预测值非常接近。图 7(c)和图 7(f)中的山影图预测值比山体阴影图的真实值(图 7(d)和图 7(e))蕴含了更丰富的光照细节特征。因此, DEM 特征提取模块不仅能有效地提取山影图的纹理特征, 还能够有效学习 DEM 的坡度和坡向等几何特征。

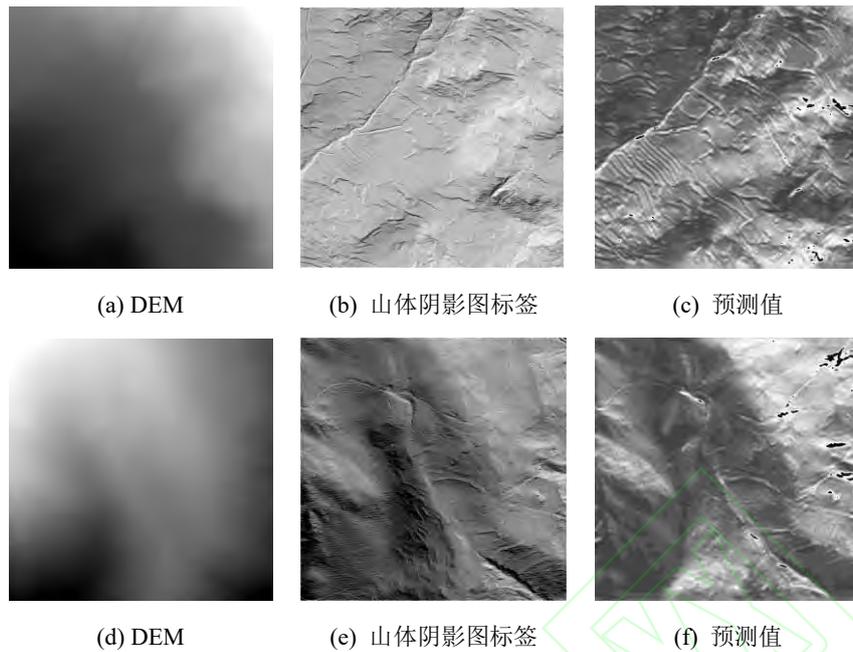


图 7 DEM 特征提取模块的预测结果

Fig.7 Prediction of the DEM feature extraction model

3.2 MMLD 模型的滑坡识别结果

滑坡识别模型的预测精度如表 1 所示，其中，模型将输入遥感数据的像元分为滑坡和背景两大类，这两类对象的平均值用于衡量模型的总体预测精度。比较各项指标的平均值可知，所有模型中平均精度最高的模型是本文提出的 MMLD 模型，最高的平均交并比、准确率和 F1 值分别为 0.664、0.749 和 0.76。精度最高的对比模型为 SeaFormer，MMLD 将 SeaFormer 的平均交并比、准确率和 F1 分别提升了 3.6%、6.5%和 2.8%。

进一步比较滑坡类的各项评价指标可知，本文提出的 MMLD 模型取得了最高的交并比、准确率和 F1，分别为 0.373、0.520 和 0.543。精度最高的对比模型为 SeaFormer，MMLD 将 SeaFormer 的滑坡类交并比、准确率和 F1 分别提升了 9.4%、22.6%和 6.8%。

表 1 滑坡识别模型之间的精度比较

Tab.1 Comparing the accuracy of the landslide detection models

模型	类别	交并比	准确率	召回率	F1
ResU-Net	滑坡	0.191	0.249	0.455	0.322
	背景	0.898	0.968	0.925	0.946
	平均值	0.544	0.608	0.690	0.634
LandsNet	滑坡	0.264	0.394	0.446	0.418
	背景	0.934	0.969	0.962	0.965
	平均值	0.599	0.681	0.704	0.691
HRNet	滑坡	0.264	0.394	0.446	0.418
	背景	0.934	0.969	0.962	0.965
	平均值	0.599	0.681	0.704	0.691
SeaFormer	滑坡	0.341	0.424	0.634	0.508
	背景	0.942	0.982	0.958	0.970
	平均值	0.641	0.703	0.796	0.739

	滑坡	0.373	0.520	0.568	0.543
MMLD	背景	0.955	0.979	0.974	0.977
	平均	0.664	0.749	0.771	0.760

图 8(a)和图 8(b)对比了 MMLD 模型与 SeaFormer 模型的滑坡识别可视化结果,可以看出,图 8(a)右侧有较多误检的滑坡,图 8(a)降低了滑坡误检率。虽然 MMLD 模型的召回率低于 SeaFormer,但是 MMLD 的 $F1$ 最高,表明在 MMLD 模型在准确率和召回率之间实现了更好的平衡。

上述实验结果表明,本文提出的 MMLD 模型达到了最高的滑坡识别精度。主要原因在于:MMLD 模型能够自动提取 DEM 和山影图数据的特征,并且综合利用山体阴影图和 DEM 两个模态之间的互补信息进行滑坡识别。

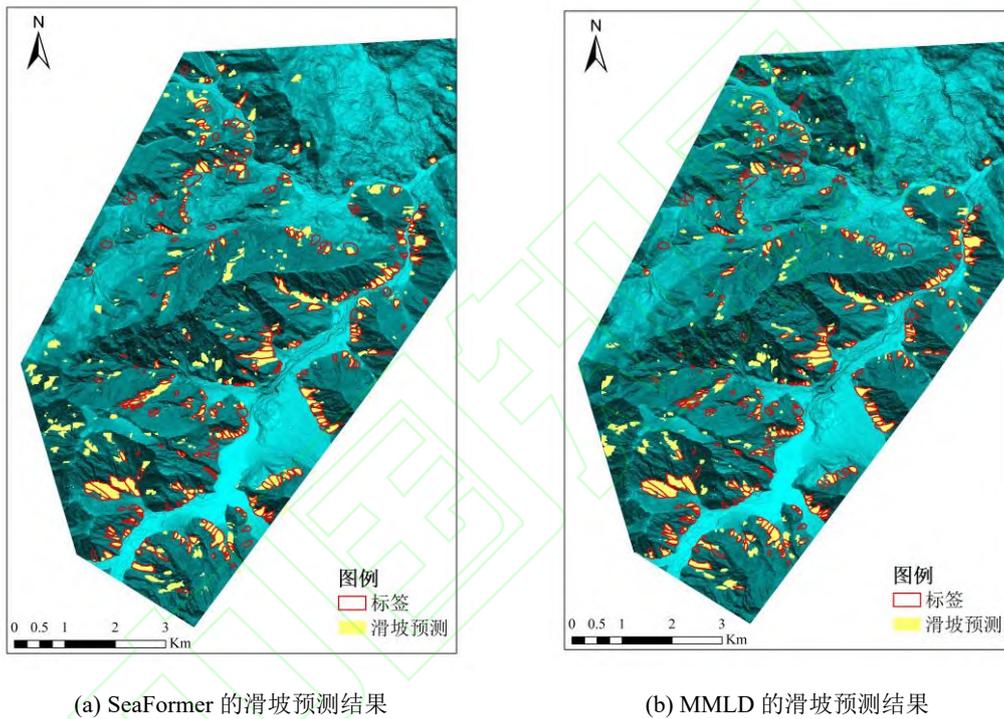


图 8 滑坡预测结果可视化

Fig.8 Visualization results of landslide prediction

4 结语

本文研究了如何利用 LiDAR 数据破解西南山区植被覆盖下的滑坡识别问题。结果表明:(1)LiDAR 生成的 DEM 和山影图有助于消除植被覆盖的干扰,显著提升滑坡识别的准确性。(2)通过人工智能模型进行自动识别植被覆盖滑坡具备可行性,深度学习技术在智能滑坡识别问题上具有巨大的发展潜力。(3)综合利用 DEM 和山影图等不同模态的遥感数据有助于提升滑坡识别的精度。

在未来的研究中,将进一步研究综合利用合成孔径雷达影像和光学影像等多源遥感数据建立更准确的滑坡识别模型。同时,也将研究深度学习模型的可解释性,揭示深度学习滑坡识别模型的决策依据。

参考文献

- [1] Ge D, Dai K, Guo Z, et al. Early Identification of Serious Geological Hazards with Integrated Remote Sensing Technologies: Thoughts and Recommendations[J]. *Geomatics and Information Science of Wuhan University*, 2019, 44(7): 949-956 (葛大庆, 戴可人, 郭兆成, 等. 重大地质灾害隐患早期识别中综合遥感应用的思考与建议[J]. *武汉大学学报(信息科学版)*, 2019, 44(7): 949-956)
- [2] Wang X, Fan X, Xu Q, et al. Change Detection-Based Co-seismic Landslide Mapping Through Extended Morphological Profiles and Ensemble Strategy[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 187: 225-239
- [3] Zhang L, Dai K, Deng J, et al. Identifying Potential Landslides by Stacking-InSAR in Southwestern China and its Performance Comparison with SBAS-InSAR[J]. *Remote Sensing*, 2021, 13(18): 3662
- [4] Xu Q, Guo C, Dong X, et al. Mapping and Characterizing Displacements of Landslides with InSAR and Airborne LiDAR Technologies: A Case Study of Danba County, Southwest China[J]. *Remote Sensing*, 2021, 13(21): 4234
- [5] Pawluszek K. Landslide Features Identification and Morphology Investigation Using High-resolution DEM Derivatives[J]. *Natural Hazards*, 2019, 96(1): 311-330
- [6] Chu H, Yin Y, Cao F. Research on Deformation Monitoring of Large Collapses and Landslides Based on 3D Laser Scanning Technology[J]. *Hydrogeology & Engineering Geology*, 2015, 42(3): 128-134 (褚宏亮, 殷跃平, 曹峰, 等. 大型崩滑灾害变形三维激光扫描监测技术研究[J]. *水文地质工程地质*, 2015, 42(3): 128-134)
- [7] Sato H, Hasegawa H, Fujiwara S, et al. Interpretation of Landslide Distribution Triggered by the 2005 Northern Pakistan Earthquake Using SPOT-5 Imagery[J]. *Landslides*, 2007, 4(2): 113-122
- [8] Huang R, Li W. Analysis of the Geo-hazards Triggered by the 12 May 2008 Wenchuan Earthquake, China [J]. *Bulletin of Engineering Geology and the Environment*, 2009, 68(3): 363-371
- [9] Chen W, Li X, Wang Y, et al. Forested Landslide Detection Using LiDAR Data and the Random Forest Algorithm: A Case Study of the Three Gorges, China[J]. *Remote sensing of environment*, 2014, 152: 291-301.
- [10] Li X, Cheng X, Chen W, et al. Identification of Forested Landslides Using Lidar Data, Object-Based Image Analysis, and Machine Learning Algorithms[J]. *Remote sensing*, 2015, 7(8): 9705-9726
- [11] Gorsevski P, Brown M, Panter K, et al. Landslide Detection and Susceptibility Mapping Using LiDAR and An Artificial Neural Network Approach: A Case Study in the Cuyahoga Valley National Park, Ohio[J]. *Landslides*, 2016, 13(3): 467-484
- [12] Mezaal M, Pradhan B. An Improved Algorithm for Identifying Shallow and Deep-seated Landslides in Dense Tropical Forest from Airborne Laser Scanning Data[J]. *Catena*, 2018, 167: 147-159
- [13] Syzdykbayev M, Karimi B, Karimi H A. Persistent Homology on LiDAR Data to Detect Landslides[J]. *Remote Sensing of Environment*, 2020, 246: 111816
- [14] Veen M, Porter M, Lato M, et al. Using Tree Stems in Multi-temporal Terrestrial Lidar Scanning Data to Monitor Landslides on Vegetated Slopes[J]. *Landslides*, 2022: 1-12
- [15] Tang X, Liu M, Zhong H, et al. MILL: Channel Attention-Based Deep Multiple Instance Learning for Landslide Recognition[J]. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 2021, 17(2s): 1-11
- [16] Ji S, Yu D, Shen C, et al. Landslide Detection from an Open Satellite Imagery and Digital Elevation Model Dataset Using Attention Boosted Convolutional Neural Networks[J]. *Landslides*, 2020, 17: 1337-1352
- [17] Shi W, Zhang M, Ke H, et al. Landslide Recognition by Deep Convolutional Neural Network and Change Detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(6): 4654-4672.

- [18] Fang C, Fan X, Zhong H, et al. A Novel Historical Landslide Detection Approach Based on LiDAR and Lightweight Attention U-Net[J]. *Remote Sensing*, 2022, 14(17): 4357
- [19] Tang X, Tu Z, Wang Y, et al. Automatic Detection of Coseismic Landslides Using A New Transformer Method[J]. *Remote Sensing*, 2022, 14(12): 2884
- [20] Li H, He Y, Xu Q, et al. Detection and Segmentation of Loess Landslides via Satellite Images: A Two-phase Framework[J]. *Landslides*, 2022, 19(3): 673-686
- [21] Ghorbanzadeh O, Shahabi H, Crivellari A, et al. Landslide Detection Using Deep Learning and Object-Based Image Analysis[J]. *Landslides*, 2022, 19(4): 929-939
- [22] Wang X, Fang C, Tang X, et al. Research on Emergency Evaluation of Landslides Induced by Luding Ms 6.8 Earthquake[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(1): 25-35 (王欣, 方成勇, 唐小川, 等. 泸定Ms 6.8地震诱发滑坡应急评价研究[J]. *武汉大学学报(信息科学版)*, 2023, 48(1): 25-35)
- [23] Chandra N, Sawant S, Vaidya H. An Efficient U-Net Model for Improved Landslide Detection from Satellite Images[J]. *PFG—Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 2023: 1-16
- [24] Soares L P, Dias H C, Garcia G P B, et al. Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-induced Landslides in Brazil[J]. *Remote Sensing*, 2022, 14(9): 2237
- [25] Xu Q. Understanding and Consideration of Related Issues in Early Identification of Potential Geohazards[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1651-1659 (许强. 对地质灾害隐患早期识别相关问题的认识与思考[J]. *武汉大学学报(信息科学版)*, 2020, 45(11): 1651-1659)
- [26] Najafifar A, Hosseinzadeh J, Karamshahi A. The Role of Hillshade, Aspect, and Toposhape in the Woodland Dieback of Arid and Semi-arid Ecosystems: A Case Study in Zagros Woodlands of Ilam Province, Iran[J]. *Journal of Landscape Ecology*, 2019, 12(2): 79-91
- [27] Guth P, Kane M. Slope, Aspect, and Hillshade Algorithms for Non-square Digital Elevation Models[J]. *Transactions in GIS*, 2021, 25(5): 2309-2332
- [28] Wu H, Liang C, Liu M, et al. Optimized HRNet for Image Semantic Segmentation[J]. *Expert Systems with Applications*, 2021, 174: 114532.
- [29] Zhu J, Fang L, Ghamisi P. Deformable Convolutional Neural Networks for Hyperspectral Image Classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(8): 1254-1258.
- [30] Wan Q, Huang Z, Lu J, et al. Seaformer: Squeeze-enhanced Axial Transformer for Mobile Semantic Segmentation[J]. *arXiv preprint arXiv:2301.13156*, 2023.
- [31] Qi W, Wei M, Yang W, et al. Automatic Mapping of Landslides by the ResU-Net[J]. *Remote Sensing*, 2020, 12(15): 2487.
- [32] Yi Y, Zhang W. A New Deep-Learning-Based Approach for Earthquake-Triggered Landslide Detection From Single-Temporal RapidEye Satellite Imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 6166-6176.