引文格式：邱文剑,王晓楠,赵静,等. 融合双路径编码的无人机影像灾后损毁地物识别[J]. 地理空间信息, 2026, 24(3): 78-83. doi:10. 3969/j.issn. 1672-4623.2026.03.016

融合双路径编码的无人机影像灾后损毁地物识别

邱文剑[1]，王晓楠[2*]，赵　静[1]，曾文浩[1]，曾飞雪[1]
（1. 湖北省自然资源厅 测绘应急保障中心，湖北 武汉 430071；2. 中国地质大学（武汉）地理与信息工程学院，湖北 武汉 430000）

摘　要：随着无人机遥感技术的快速发展，高分辨率影像已广泛应用于灾后损毁地物识别，但传统方法难以充分捕获影像中丰富的空间纹理和语义信息，易出现边界模糊、细节丢失和小尺度目标漏检等问题，因此提出了一种融合双路径编码的无人机影像地物损毁识别方法。采用卷积神经网络与 Transformer 双重编码结构分别提取局部纹理和全局上下文信息，弥补单一网络特征表达的不足；通过改进的多尺度金字塔池化模块整合多尺度特征，提升对不同尺度地物形态的识别能力；引入结合类别先验信息的动态语义提示机制，提高对低对比度区域和复杂类别的区分能力。实验结果表明，该方法的总体精度等多项指标优于现有主流模型，有效提升了无人机影像灾后损毁地物的识别精度。

关键词：无人机影像；语义分割；SAM；损毁地物识别
中图分类号：P231　　**文献标志码：**B　　**文章编号：**1672-4623（2026）03-0078-06

Post-disaster Damaged Terrain Object Recognition in UAV Images Using Dual-path Coding Fusion

QIU Wenjian[1], WANG Xiaonan[2], ZHAO Jing[1], ZENG Wenhao[1], ZENG Feixue[1]
(1. Emergency Mapping Support Center, Department of Natural Resources of Hubei Province, Wuhan 430071, China;
2. School of Geography and Information Engineering, China University of Geosciences (Wuhan), Wuhan 430000, China)

Abstract: With the rapid development of UAV remote sensing technology, high-resolution image has been widely utilized for post-disaster damaged terrain object recognition. However, the traditional methods often struggle to capture rich spatial textures and semantic information effectively, which leads to blurred boundaries, loss of fine details, and omission of small-scale targets. To overcome these issues, we proposed a dual-path coding fusion approach for damaged terrain object recognition in UAV images. The proposed method incorporates a dual-path coding architecture based on convolutional neural network and Transformer, which could extract both local texture features and global contextual representations, addressing the shortcomings of single network architecture. Additionally, a refined multi-scale pyramid pooling module is introduced to integrate features at different scales, enhancing the model's ability to recognize terrain objects with varying shapes and sizes. Furthermore, a dynamic semantic prompting mechanism based on category prior knowledge is proposed to improve discrimination in low-contrast and complex scenes. Experimental results demonstrate that the proposed method outperforms mainstream models in terms of overall accuracy and other key evaluation metrics, significantly improving the precision of post-disaster damaged terrain object recognition.

Key words: UAV image, semantic segmentation, SAM, damaged terrain object recognition

近年来滑坡、洪涝、泥石流等自然灾害频繁发生，不仅对生态系统的稳定性造成了严重破坏，也给人类生命财产安全带来了巨大威胁[1]。据统计，2024年全国因各类自然灾害导致的直接经济损失高达4 011.1亿元，其中洪涝和地质灾害造成的受灾人次占比超过50%[2]。重大自然灾害发生时，灾区常出现通信中断、道路损毁等情况，导致灾情信息无法及时传递，严重影响抢险救援的决策和部署，进而引发更大范围的经济损失和次生灾害[3]。因此，尽快获取灾区影像信息并高效、精准地识别损毁地物，对于应急救援、灾情评估和灾后重建工作具有重要意义。

无人机遥感技术的快速发展为灾后监测提供了全新的观测手段与数据支持。无人机可实现多角度、多时相的高分辨率影像采集，有效克服了卫星遥感重访周期长、空间分辨率低等局限[4-5]。然而，无人机采集的高分辨率影像数据量庞大且信息复杂，传统人工目视判读方式已无法满足快速、精准的灾害评估需求。因此，基于计算机视觉的自动化影像解译方法逐渐成为研究热点，其中语义分割技术因其能实现像素级的精细识别，在地物提取和灾后损毁识别任务中得到了

项目来源：基于遥感影像AI智能判别的地质灾害应急测绘响应技术研究（ZRZY2025KJ50）。
第一作者简介：邱文剑（1982—），硕士，从事测绘应急保障、土地资源管理工作，E-mail：6331133@qq.com。
通信作者：王晓楠（2002—），研究生在读，研究方向为灾后损毁地物识别，E-mail：wangxn_cug@163.com。

广泛应用。全卷积网络（FCN）[6]将传统卷积神经网络（CNN）的全连接层替换为卷积层，实现了任意输入尺寸图像的像素级预测，为后续语义分割在遥感影像分析领域的广泛应用奠定了基础；随后基于FCN架构的多种分割框架相继被提出，如U-Net[7]、PSPNet[8]、DeepLabV3+模型[9-10]、ENet[11]等，但上述模型的特征提取仍受卷积和池化操作中有限感受野的影响，难以有效捕捉全局上下文信息和目标分布，整体分割效果仍存在提升空间。近年来Transformer架构在自然语言处理领域的成功应用推动了其在计算机视觉领域的快速发展，衍生出一系列基于Transformer的先进语义分割算法[12-15]，虽然在捕获图像整体语义关系、增强长距离依赖信息等方面表现突出[16]，但仍存在计算开销大、对局部细节关注不足以及在复杂场景中难以精准分割小目标等问题。随着视觉基础模型的快速发展，SAM[17]是一种基于大规模样本集预训练的通用分割框架，采用编码器—解码器结构，可实现对任意图像的高效分割，且通过微调能灵活适配多种下游分割任务，为探索基于无人机影像的灾后损毁地物识别方法提供了重要的理论基础和技术参考。

尽管基于自然图像的语义分割研究已取得显著进展，但将现有方法直接应用于灾后无人机影像的损毁地物识别任务仍面临诸多困难与挑战：首先灾后无人机影像中地表特征复杂多样，相同语义类别在不同尺度下往往呈现不同的纹理、形状和颜色，增加了模型的分割难度；其次损毁目标通常表现为结构破碎、形态不完整和边界模糊，地物之间存在模糊过渡区域，进一步加大了语义识别与空间分割的复杂性。鉴于此，本文提出了一种融合双路径编码的无人机影像灾后损毁地物识别方法，以增强模型在复杂灾害场景中的适应性和边界分割能力，有效提升不同类型、尺度损毁地物的识别精度。

1　研究区与数据处理

本文选取湖北省恩施土家族苗族自治州恩施市屯堡乡马者村作为研究区。2024年7月21日受连日强降雨影响，山体失稳垮塌，引发该地区大面积泥石流，造成道路阻断、建筑损毁，灾情极为严重。研究区地形起伏大、坡面结构复杂，滑坡体与周边地物高度混杂，显著增加了灾后损毁地物的识别难度。灾后第一时间采用多旋翼无人机对滑坡核心区域开展高分辨率航拍，获取了30.3585°~30.3725°N、109.2948°~109.3080°E范围的影像数据，空间分辨率为0.1 m；经几何校正和正射处理后，采用30%重叠率的滑动窗口裁剪划分为700幅子影像。结合灾前遥感资料与实地调查信息，利用开源标注工具Elseg对各子影像进行逐像素精细标注。数据集中包括损毁建筑（65）、未损毁建筑（84）、损毁道路（46）、未损毁道路（77）、水体（11）、植被覆盖区（213）、车辆（34）和滑坡体（149）8种典型地物。将数据集按8∶2的比例划分训练集和测试集。灾后场景影像及其语义分割标注见图1。

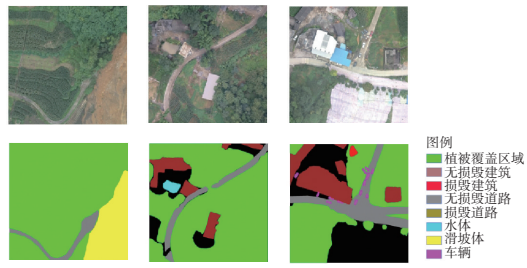


图1　灾后场景影像及其语义分割标注图

2　研究方法

2.1　技术路线

首先获取恩施滑坡灾害数据，并通过数据增强生成完整的训练与验证样本；再以SAM为基础框架，结合CNN与Transformer的双分支编码器，引入改进的金字塔池化模块与动态语义提示机制，形成能融合多尺度特征与语义信息的改进模型；然后分别对基线模型与改进模型进行训练，并通过精度评估模块开展性能对比，评价指标包括平均交并比（mIoU）、F_1-score、精确率、准确率和召回率等；最后对验证数据集的识别结果进行可视化分析，以展示模型在不同类别地物上的分类效果。

2.2　网络结构

本文基于SAM提出了一种融合双路径编码的分割模型（DPC-SAM）。①在输入影像的同时送入SAM的ViT图像编码器和一个轻量化CNN编码器进行特征提取。ViT编码器将输入影像划分为固定大小的影像块，并通过自注意力机制捕捉长距离依赖关系，重点提取损毁区域与背景之间的全局语义信息，关注灾后场景中地物类别的上下文特征；CNN编码器基于改进的ResNet-18结构[18]，保留前13层卷积模块用于提取地物边缘、纹理等局部细节特征，并移除后续5层卷积层，以减轻计算负担，确保后续特征融合阶段两类特征在空间位置上一一对应。②将ViT与CNN提取的特征通过跨模态特征交互机制进行融合，采用自适应加权策略，动态调整全局语义信息与局部细节特征的融合比例，既保留了损毁区域的整体结构，又强化了边缘细节表达。③将融合特征输入改进的金字塔池化模块，通过多尺度上下文信息提取，实现对不同尺度

目标的综合感知。为进一步提升关键区域的分割精度，结合空间注意力和通道注意力机制，动态调整特征图中不同位置和不同通道的重要性，有效聚焦于灾后场景中的损毁区域。④根据输入影像自适应生成潜在语义提示，并与可学习的静态提示嵌入相结合，通过交叉注意力机制强化提示信息与影像特征的关联性，提升模型对地物类别间关系的表达能力。⑤在解码器阶段，利用多层Transformer结构实现语义提示与图像特征的深度交互，生成带有提示引导特性的优化特征；再经过多层感知机处理生成通道权重，并进一步计算加权特征表示。加权特征通过上采样和边缘裁剪恢复至原始分辨率，在通道维度施加Softmax操作，输出最终的像素级分割结果。

2.3 跨模态特征交互机制

为充分发挥ViT与CNN编码器的优势，本文设计了一种跨模态特征交互机制，通过全局上下文信息与局部细节特征的高效协同，有效增强了模型在复杂灾后场景中的表达能力。本文采用动态加权策略，可根据不同场景自适应调整两类特征的贡献比例 α，实现语义信息与纹理信息的平衡，得到融合特征 F_{fusion}。该机制有效缓解了单一编码器在特征表达上的局限性，使模型在处理具有复杂地物分布的灾后遥感影像时获得更精准的分割效果。

2.4 改进的金字塔池化模块

灾后遥感影像不仅包含多尺度目标，还存在复杂的背景干扰，给模型特征提取和分类带来了巨大的挑战。为提升模型对多尺度特征的提取与表达能力，本文在解码阶段设计了改进的金字塔池化模块，并结合空间—通道注意力机制，增强模型对不同尺度和关键区域特征的关注能力。首先在多组尺度因子 $\{r_1, r_2, \cdots, r_n\}$ 下对 F_{fusion} 进行自适应平均池化，生成一系列多尺度特征 $\{F_{r_1}, F_{r_2}, \cdots, F_{r_n}\}$；然后将每个尺度特征图经过卷积层统一通道数量，并通过上采样操作恢复至原始分辨率；最后拼接所有尺度的特征图，形成多尺度特征表示，即

$$F_{\text{multi}} = \text{Concat}\left(\left\{U(\text{Conv}(F_{r_i}))\right\}_{i=1}^{n}\right) \tag{1}$$

传统金字塔池化虽然可在一定程度上缓解尺度变化带来的问题，但在处理高分辨率无人机影像时往往存在局部细节损失和特征冗余的情况。因此，本文在多尺度特征融合后进一步引入空间注意力机制与通道注意力机制，以增强模型对关键区域和重要通道的响应能力。空间注意力机制通过逐通道卷积与Sigmoid激活生成空间权重 W_s，动态调整特征图中不同空间位置的重要性，从而聚焦于灾后场景中的关键区域。通道注意力机制则采用全局平均池化与逐层卷积生成通道权重 W_c，用于增强与灾后地物相关的重要通道，抑制冗余信息。

$$W_s = \text{Sigmoid}(\text{Conv}_{1\times1}(F_{\text{multi}})) \tag{2}$$

$$W_c = \text{Sigmoid}(\text{Conv}_{1\times1}(\text{ReLU}(\text{Conv}_{1\times1}(\text{GAP}(F_{\text{multi}}))))) \tag{3}$$

将 W_s 和 W_c 分别作用于融合特征，得到增强后的特征表示，即

$$F_{\text{enhanced}} = W_c \odot (W_s \odot F_{\text{multi}}) \tag{4}$$

改进的金字塔池化能反映不同空间位置与通道维度的特征响应差异，实现对小尺度与大尺度目标的统一感知，提升了模型在复杂灾后场景中的分割性能。

2.5 动态语义提示机制

传统方法中模型常依赖于手工设计或预定义的提示信息来辅助特征理解，不仅灵活性差，而且在面对灾后复杂影像时易受场景变化的影响。因此，本文提出了一种动态语义提示机制，使模型能根据输入影像的特征自动生成语义提示，实现了提示信息从静态设计向动态生成的转变。假设 $F_{\text{enhanced}} \in R^{H\times W\times C}$，首先通过卷积层生成初始权重张量 $Z \in R^{H\times W\times M}$，$M$ 为预设的提示数量。为获得不同空间位置在各语义提示上的注意力分布，对提示维度进行Softmax归一化，则有：

$$A_{h,w,m} = \frac{\exp(Z_{h,w,m})}{\sum_{m'=1}^{M} \exp(Z_{h,w,m'})} \tag{5}$$

式中，exp()为指数函数；h、w、m 分别为特征图的高度、宽度和提示维度索引。

基于注意力分布，模型对特征图进行加权聚合，生成 M 个动态语义提示嵌入 $\{T_1, T_2, \cdots, T_M\}$：

$$\boldsymbol{T}_m^{\text{dyn}} = \sum_{h=1}^{H}\sum_{w=1}^{W} A_{h,w,m} F_{\text{enhanced}} \tag{6}$$

为进一步增强提示特征的语义表达能力，本文引入可学习的静态嵌入矩阵 $\boldsymbol{T}_{\text{stat}}$ 提供语义先验信息，与动态提示通过交叉注意力机制进行深度融合。融合过程可表示为：

$$\boldsymbol{T}_{\text{out}}^{\text{stat}} = \boldsymbol{T}_{\text{stat}} + \text{Softmax}\left(\frac{\boldsymbol{T}_{\text{stat}}\boldsymbol{W}_Q(\boldsymbol{T}^{\text{dyn}}\boldsymbol{W}_K)^{\text{T}}}{\sqrt{d}}\right)(\boldsymbol{T}^{\text{dyn}}\boldsymbol{W}_V) \tag{7}$$

式中，$\boldsymbol{W}_Q$、$\boldsymbol{W}_K$、$\boldsymbol{W}_V$ 为可学习投影矩阵；d 为缩放因子，避免梯度爆炸。

交叉注意力机制允许静态提示根据动态提示调整其表示，从而捕捉当前输入特征中的差异性信息，静态嵌入矩阵提供语义先验以加强全局建模能力，而动

态提示则根据输入特征自适应调整提示内容。$\boldsymbol{T}_{\text{out}}^{\text{stat}}$ 包含更丰富的上下文信息，有助于模型在灾后场景下理解不同地物之间的类别关系。残差连接与归一化操作保持信息传递过程的连续性和稳定性，进一步增强了提示信息的判别能力。

2.6 Transformer解码器

特征优化与提示生成阶段完成后，将影像特征与语义提示嵌入拼接作为Transformer解码器的输入序列 F_{dec}。解码器首先利用多头自注意力机制提取序列内部的全局依赖关系，并通过交叉注意力模块融合提示信息与特征信息，生成包含提示引导优化的特征，不仅强化了提示与特征之间的联系，还提高了模型对复杂语义关系的感知能力；再将优化特征输入多层感知机超网络，生成通道权重 W_{mask}，并进一步构建加权特征表示，即

$$M_i = \sum_{c=1}^{C} W_{\text{mask}}(c) F_{\text{dec}} \tag{8}$$

加权特征经上采样和边缘裁剪后恢复至原始分辨率。在通道维度施加Softmax操作，确定每个像素的预测类别，生成最终输出结果。

2.7 损失函数

为兼顾损毁区域的分类准确性与边界轮廓的完整性，本文设计了基于加权组合的混合损失函数。该函数由交叉熵损失和Dice损失两部分组成，通过调整权重平衡二者的贡献，以实现对像素级分类和区域形状感知的协同优化。交叉熵损失衡量了模型预测概率分布与真实标签之间的差异，即

$$L_{CE} = -\frac{1}{N}\sum_{i=1}^{N}\sum_{c=1}^{C} y_{i,c}\log(\dot{y}_{i,c}) \tag{9}$$

式中，N 为样本像素总数；C 为类别数量；$y_{i,c}$ 为像素 i 在类别 c 下的真实标签；$\dot{y}_{i,c}$ 为模型预测的概率值。

Dice损失通过比较预测区域与真实区域的重叠程度，有效缓解类别不平衡对模型训练的影响，计算公式为：

$$L_{\text{Dice}} = 1 - \frac{2\sum_{i=1}^{N} y_i \dot{y}_i}{\sum_{i=1}^{N} y_i + \sum_{i=1}^{N} \dot{y}_i + \epsilon} \tag{10}$$

式中，ϵ 为防止分母为零的平滑项。

综合上述两部分，得到最终损失函数 $L_{\text{total}} = 0.2L_{CE} + 0.8L_{\text{Dice}}$。通过该加权混合损失函数，模型能在提高分类准确率的同时，更好地保持损毁区域边缘的完整性，从而提升整体的分割效果。

3 实验与结果分析

3.1 实验设置与评估指标

为验证本文方法的有效性，选取ENet、PSPNet、DeepLabV3+、SAM四种具有代表性的语义分割模型作为基线，进行对比实验。本文在NVIDIA GeForce RTX 3090 GPU平台上，基于PyTorch深度学习框架完成模型训练与验证。PSPNet模型以ResNet-50为主干网络，采用多阶段学习率调度策略，设置初始学习率为0.001，动量系数为0.9，L2正则化权重衰减为 1×10^{-4}，幂次参数和辅助损失权重分别为0.9和0.4。ENet和DeepLabV3+模型采用相同的学习率策略，动量和权重衰减系数分别为0.9和 1×10^{-4}，以加快收敛并保持梯度平稳性。SAM模型以ViT-Base版本为图像编码器，冻结其参数，仅对掩码解码器部分进行微调，简称为SAM-Frozen。DPC-SAM模型采用相同的训练策略，优化器采用AdamW，β_1 和 β_2 分别为0.9和0.999，权重衰减系数为0.01，以充分利用预训练特征并实现语义分割任务的快速适配。将所有输入影像统一裁剪为713像素×713像素，并进行随机缩放、水平翻转和旋转等增强处理。训练过程中，PSPNet、DeepLabV3+和SAM模型均采用批量大小为4的随机梯度下降优化算法。损失函数方面，PSPNet和DeepLabV3+模型采用标准交叉熵损失；SAM模型则结合交叉熵损失和Dice损失，权重比设为0.2和0.8，以减缓类别不平衡并提升分割边界的细节表达能力。本文选取总体精度（OA）、平均 F_1-score和mIoU等指标来衡量模型在遥感语义分割任务中的准确性和泛化能力。

3.2 不同语义分割网络的识别结果比较

本文在恩施滑坡数据集上对基线方法和本文方法进行了训练和测试，并将各模型输出的语义分割结果与人工标注的真值进行对比。各模型在测试集上的评价指标见表1，可以看出，本文方法的 OA 最高（96.46%），较DeepLabV3+和PSPNet略有提升，明显优于ENet和SAM-Frozen；本文方法在损毁建筑、滑坡体和损毁道路等边界复杂、形态不规则的类别上mIoU、平均 F_1-score均优于其他模型，说明本文方法能更好地处理灾后场景中复杂的地物交错和地表扰动，有效避免不同类别之间的混淆。对于水体和车辆类别，由于其在数据集中占比较低且形态细碎，所有模型的识别效果均较差，但本文方法在车辆类别上的识别精度，相比ENet和PSPNet模型具有明显优势。

各模型在典型测试区域的地物识别可视化结果见

表1 不同语义分割模型在恩施滑坡数据集上的性能对比表

模型	植被覆盖区	无损毁建筑	损毁建筑	无损毁道路	损毁道路	水体	滑坡体	车辆	mIoU	平均F_1-score	*OA*
ENet	96.86	63.75	42.81	31.40	0.17	0.00	94.87	0.00	41.23	47.70	95.11
PSPNet	96.28	77.84	57.98	59.81	60.17	0.00	93.04	0.00	55.43	63.04	95.99
DeepLabV3+	96.42	62.44	51.11	57.09	56.02	0.00	94.05	0.00	52.14	60.52	95.71
SAM-Frozen	91.10	49.34	39.39	27.64	25.12	0.00	69.25	0.00	37.73	47.90	90.94
本文方法	6.63	77.70	57.23	53.47	49.19	3.95	92.69	14.13	55.62	65.34	96.46

图2，可以看出，本文方法在建筑物、道路和滑坡体边缘的分割表现更加精细，边界更加清晰，与地物实际轮廓吻合程度较好，展现出良好的地物识别能力。这得益于模型中引入的改进金字塔池化模块和空间通道注意力机制，前者通过多尺度上下文信息提取，使模型能同时感知大范围结构和局部细节；后者则动态调整关键区域和重要通道的权重，从而强化了模型对损毁区域与背景交界处的敏感性。

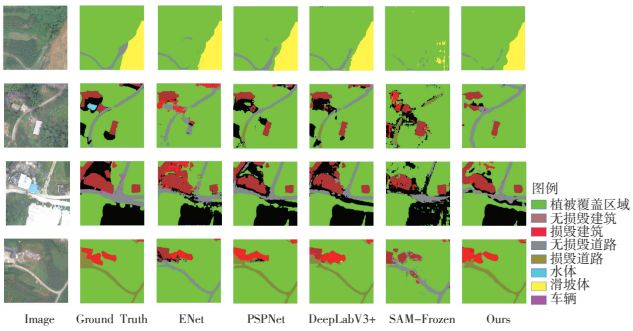


图2 不同模型在恩施滑坡数据集上的识别结果可视化

DeepLabV3+和PSPNet模型虽然在整体轮廓识别上表现较好，但在局部复杂区域（如滑坡边界交错处、破碎道路的过渡区域）易出现边界模糊、细节缺失和类别混淆等问题，这与其依赖固定感受野的卷积结构有关，模型难以充分捕获长距离依赖和复杂上下文关系。ENet模型由于模型结构较为轻量化，分割结果表现出边缘粗糙、目标形态不完整等局限性。SAM-Frozen模型在多类地物中存在语义误判和区域漂移，尤其在损毁道路与滑坡体的区分上表现较差。这是因为其作为通用分割框架，缺乏针对遥感场景的优化设计，难以适应灾后影像中的复杂类间干扰。本文方法通过将动态语义提示机制与可学习的静态嵌入相结合，增强了模型对复杂类别关系的表达和区分能力。交叉注意力机制的引入，使得提示信息与影像特征深度融合，有效提高了模型在边界复杂区域的分割表现。此外，本文方法在应对数据集类别不平衡问题时表现出较强的适应能力。交叉熵损失与Dice损失的联合策略不仅提升了小样本类别（如车辆）的识别效果，还在保证整体精度的同时，改善了边界细节的分割表现。

4 结 论

针对当前灾后遥感影像中普遍存在的地物损毁区域分布碎片化、类间纹理特征相似性高以及目标尺度变化显著等问题，本文基于SAM提出了DPC-SAM模型，通过融合CNN与Transformer的双重编码结构，实现了局部纹理细节与全局结构信息的有效互补，从而提升了模型在复杂灾害场景下的特征表达能力和地物识别精度。在边界复杂、对比度低的损毁区域，引入的动态语义提示机制能自适应调整特征权重，增强模型对关键区域的感知能力；改进的金字塔池化模块可显著提升模型捕获多尺度上下文信息的能力，从而改善小尺度目标（如车辆）和大尺度滑坡体的分割表现。在湖北省恩施土家族苗族自治州滑坡无人机影像数据集上的实验结果表明，本文方法在*OA*、mIoU和平均F_1-score等核心指标上均优于ENet、PSPNet、DeepLabV3+等主流语义分割模型，且在多类别、多尺度地物分割任务中展现出更强的场景适应性和更优的分割表现。然而，本文方法仍存在一定局限性：①在严重遮挡、多类别高度交错区域等极端复杂场景中，分割边界仍可能出现局部不连续或小范围误判；②尽管本文方法通过冻结ViT编码器降低了计算量，但在大规模区域影像分割任务中，模型推理时间仍然较长，未来需进一步探索模型轻量化改进策略；③受限于数据集样本分布，模型在车辆、水体等占比较小类别的识别精度也有待提升。

综上所述，本文方法在保证整体分割精度的同时，提升了地物边界细节的表达能力，为无人机遥感影像在灾后应急评估中的应用提供了一种高效可靠的地物损毁识别方法参考，进一步为灾后损失量化、灾情分析和救援决策等工作提供技术支持。

参考文献

[1] 刘鹏,邹崇尧,何雯,等. 基于无人机遥感的滑坡几何参数测量方法研究[J]. 地理空间信息,2023,21(1):123-126

[2] 国家防灾减灾救灾委员会办公室,应急管理部. 2024年全国自然灾害基本情况[J]. 中国减灾,2025(3):5-7

[3] 张博闻. 无人机航空遥感系统在灾害应急救援中的应

用[J]. 中国高新科技,2022(21):159-160
[4] 王晓刚,高飞云,杨磊,等. 无人机遥感技术在自然灾害应急中的应用及前景[J]. 四川地质学报,2019,39(1):158-163
[5] 安稳. 无人机遥感勘察技术在地质灾害防治中的应用研究[J]. 矿业装备,2024(7):77-79
[6] Shelhamer E,Long J,Darrell T. Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2015,39(4):640-651
[7] Ronneberger O, Fischer P, Brox T. U-Net:Convolutional Networks for Biomedical Image Segmentation[C]. Medical Image Computing and Computer-assisted Intervention (MICCAI),2015:234-241
[8] Zhao H,Shi J,Qi X,et al. Pyramid Scene Parsing Network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR),2017:6230-6239
[9] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with Atrous Separable Convolution for Semantic Image Segmentation[C]//Proceedings of the European Conference on Computer Vision (ECCV),2018:833-851
[10] Yu F,Koltun V. Multi-scale Context Aggregation by Dilated Convolutions[C]. International Conference on Learning Representations (ICLR),2016
[11] Paszke A, Chaurasia A, Kim S, et al. ENet:A Deep Neural Network Architecture for Real-time Semantic Segmentation[J]. arXiv:1606.02147,2016
[12] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An Image is Worth 16×16 Words:Transformers for Image Recognition at Scale[J]. arXiv.2010.11929,2020
[13] Xie E,Wang W,Yu Z,et al. SegFormer:Simple and Efficient Design for Semantic Segmentation with Transformers[J]. arXiv:2105.15203,2021
[14] Liu Z,Lin Y T,Cao Y,et al. SwinTransformer:Hierarchical Vision Transformer Using Shifted Windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV),2021:9992-10002
[15] Zhang Z,Huang X,Li J. DWin-HRFormer:A High-resolution Transformer Model with Directional Windows for Semantic Segmentation of Urban Construction Land[J]. IEEE Transactions on Geoscience and Remote Sensing,2023(61):1-14
[16] 刘琦,杨小华,陈柏行,等. 基于Transformer的成都市地物分类技术[J]. 地理空间信息,2023,21(12):51-53
[17] Kirillov A,Mintun E,Ravi N,et al. Segment Anything[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV),2023:4015-4026
[18] He K,Zhang X,Ren S,et al. Deep Residual Learning for Image Recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778

（上接第70页）

具有良好的精度与适应性，能高效可靠地为地质灾害隐患识别、风险评估与防治提供关键的数据支撑。

本文的研究成果可为郑州市西部山区的地质灾害风险防控提供重要的技术支持，对于提高区域地质灾害隐患的早期识别、风险预警和应急管理能力具有积极意义。

参考文献

[1] 华冲. 通南巴地区油气勘探作业区域地质灾害防治对策探讨[J]. 中国石油和化工标准与质量,2013,33(17):134-135
[2] 韩龙祖,贾丹. 遥感技术在水电站地质灾害识别与监测预警中的应用与展望[J]. 中国矿业,2023,32(增刊1):248-251
[3] 余华芬,吴迪,汪建光,等. 基于InSAR的地质灾害早期识别与监测技术研究[J]. 地理空间信息,2023,21(3):44-48
[4] 高茂宁,魏冠军,雷传金,等. 顾及时序InSAR的海东市辖区滑坡敏感性评价[J]. 地理空间信息,2024,22(5):97-101
[5] 牛敏杰,师芸,吕杰,等. 基于SBAS-InSAR技术的广安村滑坡形变监测分析[J]. 地理空间信息,2023,21(1):79-84
[6] 许强,董秀军,李为乐. 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[J]. 武汉大学学报(信息科学版),2019,44(7):957-966
[7] 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
[8] 张利军,贺思睿,张建东,等. 多源遥感技术支持下的滑坡地灾隐患识别:以常澧地区为例[J]. 自然资源遥感,2024,36(2):173-187
[9] 杨佳旺,钱建平,龙思远,等. 遥感技术在中国地质灾害中的应用[J]. 防灾减灾学报,2022,38(4):17-25
[10] 王宝红,徐郅杰,董伟,等. 焦作市地质灾害防治规划对地质环境的影响[J]. 环境与发展,2020,32(9):53-54
[11] 何宝夫. 金沙江丽江段五至七级电站区域地壳稳定性研究[D]. 北京:中国地质科学院,2010
[12] 刘智学,薛东剑. 基于Sentinel-1A数据的地表形变监测[J]. 地理空间信息,2021,19(11):92-95
[13] 李益敏,计培琨,杨雪,等. 基于PS-InSAR技术的地表形变监测与驱动力分析[J]. 地理空间信息,2024,22(9):61-66
[14] 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
[15] 周胜森,李为乐,陈俊伊,等. 西昌—香格里拉拟建高速公路廊道不良地质体遥感识别[J]. 中国地质灾害与防治学报,2022,33(6):90-102