

基于形状感知与边界细化的轻量化遥感影像滑坡提取模型

文扬^{1,2}, 欧健^{1,2}, 刘舟^{3,4*}, 余启轩³, 黄英^{1,2}, 黄郁淇^{1,2}, 岑奕^{3,4}

1. 湖南省地质灾害调查监测所, 湖南长沙 410014
2. 湖南省地质灾害监测预警与应急救援工程技术研究中心, 湖南长沙 410014
3. 湖北工业大学计算机科学与人工智能学院, 湖北武汉 430068
4. 绿色智能算力网络湖北省重点实验室, 湖北武汉, 430068

摘要: 遥感影像滑坡提取中, 目标形态复杂多变易导致分割断裂, 复杂背景易引发误检并造成边界锯齿。针对上述问题, 提出一种形状感知与边界细化网络模型 SABR-Net。该模型采用多分支异构卷积结构以增强对滑坡狭长与不规则形态的特征表达; 同时引入门控边界细化模块, 利用高层语义信息动态抑制低层特征中的背景噪声, 从而优化滑坡边缘分割质量。SABR-Net 模型在湖南省资兴市降雨诱发滑坡数据集上进行验证。实验结果表明, SABR-Net 的平均交并比 (mIoU) 与 F1 分数分别达 75.23% 和 70.87%, 综合性能优于 Trans-Unet 等七种主流模型, 且总参数量仅为 1.50M。该方法在滑坡提取精度与计算开销之间实现了良好平衡, 有效缓解了滑坡提取中的形态断裂与边界锯齿问题, 为灾害应急监测及边缘端部署提供了可行方案。

关键词: 滑坡提取; 遥感影像; 形状感知; 轻量化模型

中图分类号: P237

收稿日期: 2026-2-27

A Lightweight Landslide Mapping Model Based on Shape Awareness and Boundary Refinement

Wen Yang^{1,2}, Ou Jian^{1,2}, Liu Zhou^{3,4*}, Yu Qixuan³, Huang Ying^{1,2}, Huang Yuqi^{1,2}, Cen Yi^{3,4}

1. Hunan Institute of Geological Disaster Investigation and Monitoring, Changsha 410014, China;
2. Hunan Geological Disaster Monitoring Early Warning and Emergency Rescue Engineering Technology Research Center, Changsha 410014, China
3. School of Computer Science and Artificial Intelligence, Hubei University of Technology, Wuhan 430068, China
4. Hubei Provincial Key Laboratory of Green Intelligent Computing Power Network, Wuhan 430068, China

Abstract: In landslide mapping from remote sensing imagery, complex and highly variable target morphologies often lead to fragmented segmentation, while complex backgrounds may cause false positive detections and jagged boundaries. To address these issues, a Shape-Aware and Boundary Refinement Network (SABR-Net) is proposed. The proposed model employs a multi-branch heterogeneous convolutional structure to enhance the feature representation of narrow, elongated, and irregular landslide morphologies. Simultaneously, a gated boundary refinement module is introduced, which utilizes high-level semantic information to dynamically suppress background noise in low-level features, thereby improving the delineation quality of landslide boundaries. The SABR-Net model is validated on the rainfall-induced landslide dataset in Zixing City, Hunan Province. Experimental results demonstrate that SABR-Net achieves a mean Intersection over Union (mIoU) of 75.23% and an F1 score of 70.87%. Its comprehensive performance outperforms seven mainstream models, including Trans-UNet, while maintaining a total parameter count of only 1.50 M. The proposed method achieves a favorable balance between extraction accuracy and computational overhead, effectively alleviating the issues of

基金项目: 湖南省地质院科技计划项目 (HNGSTP202534); 湖南省自然科学基金 (2025JJ80021); 湖南省自然科学基金项目 (2025JJ80406); 湖南省地质院科技计划项目 (HNGSTP202463); 湖北省教育厅科学研究计划青年人才项目 (Q20231406)。

作者简介: 文扬 (1994-), 男, 工程师, 主要从事地质灾害机理与防治技术研究, ORCID: 0009-0007-7022-6717, Email: WenYanghpgi@163.com.

***通信作者:** 刘舟 (1989-), 男, 博士, 硕导, 讲师, 主要从事遥感影像智能解译与理解研究, ORCID: 0000-0002-4651-1370, Email: liuzhou@hbut.edu.cn.

作者贡献度说明: 文扬: 研究思路提出, 论文撰写修改; 欧健: 算法改进与论文撰写修改; 刘舟: 论文框架设计, 实验方案设计与分析; 余启轩: 数据预处理与图表设计; 黄英: 文献调研与整理, 实验结果分析; 黄郁淇: 论文图表制作; 岑奕: 研究思路讨论与论文修改审核。

morphological fragmentation and jagged boundaries. It provides a feasible solution for disaster emergency monitoring and deployment on edge devices.

Key words: Landslide mapping; Remote sensing imagery; Shape awareness; Lightweight model

引言

滑坡是指斜坡上的岩体、土体或碎屑堆积物受雨水冲刷、地震等因素影响,在重力及其他诱发因素作用下,沿着斜坡向下运动的地质现象(张玘恺等, 2020; 陈文鸿等, 2025)。作为全球最具破坏性的自然灾害之一,滑坡严重威胁着人类的生命财产安全、交通网络与基础设施建设,而我国是世界上受滑坡灾害影响最大的国家之一(李振洪等, 2022)。因此,大范围、快速且高精度的滑坡识别与监测对于灾害预警、风险评估以及灾后救援具有极其重要的现实意义。传统的滑坡识别主要依赖于人工实地踏勘和测绘专家对遥感影像的主观目视解译(Zhao *et al.*, 2017)。然而,这些传统手段不仅属于高度劳动密集型、耗时费力,而且在面对复杂地形和广袤山区时极易受到解译人员主观经验差异的干扰,从而造成结果的遗漏或不一致。(许强, 2020)

随着地球观测技术的飞速发展,利用高分辨率光学遥感影像进行滑坡智能检测已成为当前的重点研究方向(钟洪星等, 2025)。早期研究主要依靠最大似然法、支持向量机以及随机森林(吴润泽等, 2021)等传统的机器学习方法来提取滑坡信息。这些方法高度依赖于人工设计的浅层特征(如光谱、纹理和几何特征),在面对自然场景下复杂的光照变化、地形阴影以及植被覆盖时,其特征表达能力和算法的泛化潜力十分有限(毛正君等, 2025)。

近年来,深度学习技术的突破为基于遥感图像智能解译的滑坡提取带来了范式转变,尤其是卷积神经网络能够从海量数据中自动提取高维抽象语义特征,极大提升了提取效率(Jiang *et al.*, 2022)。目前,基于深度学习的遥感滑坡检测方法主要可分为四大类:①第一类是基于图像块的场景分类方法,通过判定输入的遥感影像块中是否包含滑坡体来实现粗粒度的灾害识别(Ghorbanzadeh *et al.*, 2019)。此类方法计算效率较高,但完全无法提供滑坡的具体空间位置和精细边界信息(杨昭颖等, 2022)。②第二类是基于目标检测的方法(侯梦媛等, 2023),例如基

于 YOLO (Redmon *et al.*, 2016) 或 Faster R-CNN(Ren *et al.*, 2016)等经典架构,通过生成边界框来定位滑坡主体。然而,受限于矩形框的刚性表达形式,该方法无法精细刻画滑坡极其不规则的边缘轮廓(Han *et al.*, 2023)。③第三类是基于变化检测的方法,利用灾前与灾后的双时相高分辨率遥感影像,提取滑坡诱发的地表变化区域(Amankwah *et al.*, 2022;张灿灿等, 2025)。该方法能够有效排除静态裸土和人工地物的干扰,在灾后快速损失评估中具有独特优势。然而,在灾害发生的紧急关头,往往难以第一时间获取无云的灾前高质量影像,数据获取门槛极高。④第四类是基于语义分割的方法,以 U-Net(Ronneberger *et al.*, 2015)等全卷积网络为代表,能够实现单时相遥感影像像素级的精细化分类,是目前获取高精度滑坡形态及轮廓的最主流方向(Chandra *et al.*, 2025)。尽管基于语义分割的深度学习模型取得了显著进展,但面对复杂地理环境下高分辨率遥感影像时,现有的 U-Net 类模型仍面临两个亟待解决的关键问题:(1)滑坡几何形态的极度复杂性与多尺度效应。受局部地形地质条件和滑动物理机制的差异影响,滑坡在遥感影像中呈现出高度多变的几何形状。既有顺着山谷倾泻而下的狭长条带状泥石流,也有大面积的块状岩体崩塌,如图 1 所示。传统的卷积神经网络模型由于受限于固定的局部方形感受野(如标准的 3×3 卷积),难以自适应地捕获具有极端长宽比的条状特征或宏观的全局结构,常导致长条形滑坡在预测结果中发生断裂,或大型滑坡内部出现特征缺失。(2)边界模糊与强背景干扰。滑坡区域的光谱和纹理特征通常与周围的裸土、梯田以及稀疏植被高度相似。现有的 U-Net 架构在进行跨层特征融合时,通常采用简单的直接特征拼接。这种粗暴的融合方式不可避免地将低层特征中蕴含的大量背景噪声直接引入了解码阶段,导致模型在复杂背景下产生严重的误报,且最终提取出的滑坡边界往往极其粗糙、呈现严重的锯齿状甚至发生拓扑断裂。

为了克服上述瓶颈并满足实际应用的需求,本文提出了一种全新的轻量化形状感知与边界细




图 1 典型滑坡几何形状（数据来自 Fu *et al.*, 2025）

Fig. 1 Examples of typical landslide geometries (Data from Fu *et al.*, 2025)

化网络（Shape-Aware and Boundary Refinement Network, 简称 SABR-Net），旨在实现单时相高分辨率遥感影像下高精度且高效的像素级滑坡智能提取。首先，本文构建了一个轻量级的 U-shape 网络模型架构，通过深度可分离卷积等策略大幅降低了网络的计算复杂度②其次，针对滑坡几何形态复杂多变的问题，本文设计了形状感知模块（Shape-Aware Block, 简称 SAB），通过构建多条并行的异构卷积路径（包括 1×21 、 21×1 、 7×7 以及 3×3 分支），充分提取不同尺度的滑坡几何先验信息，并利用动态注意力机制自适应地聚焦于最显著的形态特征。最后，为缓解底层背景噪声并恢复精确轮廓，本文进一步提出了形状引导边界细化模块（Shape-Guided Boundary Refinement, 简称 SGBR）。该模块利用解码器中蕴含形状先验的高层语义特征作为向导，生成通道与空间双重门控注意力，在特征拼接融合前对低层特征进行精准的重新校准，从而有效过滤了冗余噪声并锐化了滑坡边界。实验结果表明，本文提出的 SABR-Net 模型通过对复杂形态特征的精细化建模，从而在提取精度、召回率等关键指标上全面提升了滑坡提取任务的整体性能。

本文的主要贡献可归纳为以下三个方面：①构建了一种面向遥感影像的滑坡提取轻量化网络

模型。通过在网络中大量引入深度可分离卷积与瓶颈层进行特征映射，本模型在显著降低网络总参数量和计算复杂度的同时，依然保持了强大的多尺度特征表征能力，极大地提升了模型在实际地理监测场景中的部署与推理效率。②设计了形状感知模块。该模块结合了非对称长条状卷积与大尺寸全局卷积，打破了传统单一感受野的局限，有效解决了现有基于 U-Net 结构模型难以自适应捕捉滑坡复杂多变几何形态的问题。③提出了形状引导边界细化模块。该模块改变了传统 U-Net 简单的硬拼接融合范式，利用高层形状先验引导的门控机制显著抑制了低层特征带来的背景干扰，大幅提升了滑坡边界的最终分割精度和模型的抗噪能力。

1 本文方法

为了解决高分辨率遥感影像中滑坡目标形态复杂多变以及边界模糊的问题，本文提出了一种轻量化形状感知与边界细化网络模型 SABR-Net。本节将详细阐述该网络模型的总体架构，并详细介绍其两大核心组件：形状感知模块 SAB 与形状引导边界细化模块 SGBR。

1.1 模型总体架构

一步的自适应感知与空间重构，生成解码器特征 F_i^D ：

$$F_i^D = \mathcal{H}_{SAB}^D(F_i^F), i \in 1, 2, 3, 4 \quad (3)$$

最终，解码器最高层的输出特征 F_1^D 将被送入一个 1×1 的卷积分类层，并通过 Sigmoid 激活函数将特征映射压缩至区间 $[0, 1]$ ，从而生成最终的滑坡分割掩膜 $\hat{Y}$ ：

$$\hat{Y} = \sigma(\mathcal{W}_{out} * F_1^D + b) \quad (4)$$

其中， $\sigma(\cdot)$ 表示 Sigmoid 激活函数， $*$ 表示卷积运算， $\mathcal{W}_{out}$ 与 b 分别为检测头的权重与偏置项。

为避免不同激活函数的作用位置产生歧义，本文对网络内部激活策略说明如下：SABR-Net 在特征提取、通道压缩与跨层特征对齐过程中采用 GELU 激活函数，以增强中间特征表达的非线性建模能力并保留边缘区域的细微梯度变化；在 SAB 与 SGBR 模块的注意力或门控分支中采用 Sigmoid 函数，将形态注意力权重和空间门控权重约束至 $[0, 1]$ 区间，从而实现对特征响应的软选择；在最终输出头中同样采用 Sigmoid 函数，将 1×1 卷积得到的 logit 映射为像素属于滑坡类别的概率。由此，GELU 主要用于网络内部特征变换，Sigmoid 主要用于注意力/门控权重生成与二分类概率输出，二者作用位置和功能并不相同。

1.2 形状感知模块

在滑坡的高分辨率遥感影像中，目标的几何形态往往呈现出极端的长宽比（如顺着山谷倾泻的狭长条带）或宏观的全局结构（如大面积的块状崩塌）。传统的全卷积网络通常依赖固定的 3×3 局部方形感受野，难以自适应地捕获此类极端或多变的形态先验，容易导致预测掩膜中长条形滑坡发生断裂（Du *et al.*, 2026）。为此，本文设计了形状感知模块（SAB），其内部结构如图 2(b) 所示。

SAB 的核心机制在于利用多分支的异构卷积来联合提取多尺度的几何特征，并通过动态注意力机制进行自适应加权。给定输入为局部特征张量 $F_{in} \in \mathbb{R}^{C' \times H' \times W'}$ 。在编码器中，该输入对应下采样后的特征 $\mathcal{D}(F_{i-1}^E)$ ；在解码器中，该输入对应跨层融合后的特征 F_i^F 。

SAB 首先采用 1×1 卷积对输入特征 F_{in} 进行通道降维。降维后的特征依次经过批量归一化 $\mathcal{B}(\cdot)$ 与 GELU 激活函数 $\delta_G(\cdot)$ ，得到紧凑特征表达 F_{red} ，

GELU 的平滑非线性特性在降维阶段有效保留了滑坡边缘的微小梯度信息。

随后，紧凑特征 F_{red} 被并行送入四个具有不同感受野特性的分支：

1. 水平条状分支：采用 1×21 的非对称卷积，专门用于捕获横向展布的狭长特征；
2. 垂直条状分支：采用 21×1 的非对称卷积，用于提取纵向倾泻的滑坡纹理；
3. 块状感知分支：采用 7×7 的大尺寸卷积核，以提供更广阔的宏观结构感知；
4. 局部细节分支：保留标准的 3×3 卷积，用于维持对细微边缘的提取能力。

各分支提取的特征经过级联与融合后，形成多尺度形态特征张量 F_{multi} ，随后通过 1×1 卷积降维并经过 Sigmoid 函数激活，生成几何形态注意力权重图 $A_{SAB} \in \mathbb{R}^{C' \times H' \times W'}$ ：

$$A_{SAB} = \sigma(\mathcal{W}_{att} * F_{multi} + b_{att}) \quad (5)$$

其中， $\mathcal{W}_{att}$ 和 b_{att} 分别为注意力生成路径中的卷积权重和偏置。最终，生成的注意力权重图 A_{SAB} 与原始输入特征 F_{in} 进行逐元素相乘以自适应地增强滑坡的显著形态特征并抑制不相关的背景冗余。输出特征 F_{out}^{SAB} 的表达式为：

$$F_{out}^{SAB} = F_{in} \otimes A_{SAB} \quad (6)$$

1.3 形状引导边界细化模块

为了彻底消除低层特征带来的噪声并锐化滑坡轮廓，本文提出了形状引导边界细化模块（SGBR），其结构如图 2(c) 所示。SGBR 的核心逻辑是“以高带低”，即利用解码器中蕴含形状先验的高层语义特征作为门控向导（Gate Guide），对低层特征进行精准的重新校准。

SGBR 的输入由两部分组成：来自编码器的低层特征 F_{low} 以及来自上一级解码器并经过上采样的高层特征 F_{high} 。该模块的内部特征重新校准过程包含以下三个步骤：

- 1) 低层特征对齐与激活。考虑到跨层特征在语义深度和通道维度上的差异，SGBR 首先利用 1×1 卷积对低层特征进行通道对齐，并依次经过批量归一化与 GELU 激活函数，得到平滑映射后的对齐特征 F_{low}^{align} 。

2) 形状引导的门控生成。高层特征 F_{high} 经过空间卷积操作后,通过 Sigmoid 函数生成用于表征上下文形状先验的门控权重图 G_{SGBR} 。该权重图在空间像素级别上指示了真实滑坡主体的置信度区域:

$$G_{\text{SGBR}} = \sigma(\mathcal{W}_{\text{gate}} * F_{\text{high}} + b_{\text{gate}}) \quad (7)$$

3) 门控过滤与特征级联。对齐后的低层特征 $F_{\text{low}}^{\text{align}}$ 与门控权重图 G_{SGBR} 进行逐元素相乘操作。这一步起到“软掩膜 (Soft Mask)”的作用,精准地屏蔽了低层特征中的冗余背景噪声,得到被精细化和锐化的特征 F_{refined} :

$$F_{\text{refined}} = F_{\text{low}}^{\text{align}} \otimes G_{\text{SGBR}} \quad (8)$$

最后, SGBR 模块在通道维度上,将纯净的细化低层特征 F_{refined} 与原始高层特征 F_{high} 进行特征拼接,生成最终的跨层融合特征 F_i^F ,并将其传递给下一级解码器。这种门控过滤结合特征级联的设计,既有效剔除了致命的光谱干扰,又完整保留了多源特征的独立性,从而在解码阶段极大提升了滑坡边界的分割精度。

1.4 损失函数

在遥感影像滑坡提取任务中,滑坡区域(正样本)与广袤的背景区域(负样本)之间通常存在极其严重的类别不平衡问题。如果仅采用传统的像素级分类损失,网络极易陷入局部最优,倾向于将大部分像素预测为背景。为了解决这一问题,并促使网络更好地兼顾滑坡的像素级分类精度与全局形态轮廓,本文采用二元交叉熵损失(Binary Cross-Entropy Loss, 简称 BCE Loss)与 Dice 损失(Dice Loss)组成的联合损失函数来指导 SABR-Net 的端到端训练。

二元交叉熵损失 BCE Loss 独立地评估每个像素点的分类误差,能够提供平稳的像素级梯度下降方向,其数学表达式为:

$$L_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (9)$$

其中, $y_i \in \{0,1\}$ 表示第 i 个像素的真实标签,其中 $y_i = 1$ 代表滑坡, $y_i = 0$ 代表背景; $\hat{y}_i \in [0,1]$ 表示网络模型输出预测图中第 i 个像素属于滑坡的预测概率。

尽管 L_{BCE} 能够有效地促使预测概率逼近真实标签,但由于其平等地对待所有像素,在正负样本比例悬殊时,背景像素产生的累积误差会淹没滑坡目标的梯度(Lin *et al.*, 2020)。为了弥补 BCE Loss 在类别不平衡情况下的缺陷,本文引入了基于区域重叠度的 Dice Loss (Milletari *et al.*, 2016)。Dice Loss 直接从全局尺度优化预测掩膜与真实标签之间的集合相似度,对前景区域(滑坡主体)的几何形态和边缘更加敏感:

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i + \epsilon}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i + \epsilon} \quad (10)$$

其中, ϵ 为平滑系数,旨在防止预测与标签均为空时分母为零问题,并保证训练早期的梯度稳定性。在实际训练中,平滑系数 ϵ 设置为 $1e-5$ 。

最终,本文采用上述两者的线性加权和作为总损失函数,使模型在关注微观像素分类准确性的同时,亦能强化宏观的滑坡形状感知与边界吻合度:

$$L_{\text{Total}} = \lambda_1 L_{\text{BCE}} + \lambda_2 L_{\text{Dice}} \quad (11)$$

其中, λ_1 与 λ_2 为平衡两个损失项的权重超参数。在本文的实验设置中,为使模型在像素分类与区域重叠上取得最佳平衡,我们将其均设置为 1.0。该设置主要基于二者在优化目标上的互补性: BCE Loss 能够提供稳定的像素级分类监督,有助于保持背景与滑坡像素的判别能力; Dice Loss 直接优化预测掩膜与真值标签之间的区域重叠关系,对正负样本不平衡更为敏感,能够缓解滑坡像素占比较低导致的前景梯度弱化问题。

2 实验数据与结果

2.1 实验数据

为了全面客观地评估本文提出的 SABR-Net 模型在复杂自然场景与大范围区域下的滑坡提取性能,本实验采用了最新发布的资兴降雨诱发滑坡检测数据集(Rainfall-induced Landslide in Zixing - Landslide Detection Dataset, 简称 RLZX-LDD)中的卫星遥感子数据集(简称 RLZX-LDD-SAT)。该数据集来源于真实灾害场景,具有滑坡分布密集、背景地物复杂、目标尺度差异显著等特点,能够较好地反映实际灾后遥感解译任务中的复杂性与挑战性。

表 1 本文所使用的数据集

Table 1 Datasets used in this study

数据集名称	影像类型	地区	分辨率	样本总数	样本尺寸
RLZX-LDD-SAT	Gaofen-1/Gaofen-6	中国湖南省资兴市	2 米	2848	256x256




图 3 RLZX-LDD-SAT 数据集部分影像与真值标签图

Fig. 3. Sample images and labels from RLZX-LDD-SAT.

该数据集详细记录了 2024 年 7 月 26 日至 28 日期间，受台风“格美”带来的极端降雨影响，在中国湖南省资兴市引发的大规模密集型浅层滑坡群（Fu *et al.*, 2025）。该数据集研究区内的滑坡单体面积跨度极大，范围从极小的 4m 到巨型的 171,982m 不等。这种极端多变的几何形态为验证本文网络模型在多尺度下的形状感知能力提供了良好的数据基础，同时也有助于检验模型对小尺度滑坡、狭长型滑坡及大面积滑坡体的综合识别能力。在构建该数据集的真值标签（Ground Truth）时，利用了灾前的 Sentinel-2 L2A 光学影像与灾后的高分卫星影像构建 3D 时空场景，并在此基础上进行精细化的人工目视解译，从而保证了样本标注的空间准确性与可靠性。

RLZX-LDD-SAT 共计提供了覆盖整个研究区的 2848 个图像切片样本。每个图像尺寸为 256×256 像素。此外，为充分评估模型的泛化能力、全面验证网络性能并防止训练过程中的过拟合，本实验将全部样本按照 70%、20%、10% 的比例，严格随机划分为训练集（1994 个样本）、测试集（570 个样本）和验证集（284 个样本）。本实验所使用数据的具体信息如表 1 所示。值得注意的是

该数据集集中的滑坡正样本像素平均占比仅为 7.16%。这种显著的正负样本极度不均衡现象，非常适合用于检验本文模型对抗复杂背景噪声以及精细化滑坡边界的能力。RLZX-LDD-SAT 部分样本与真值标签图如图 3 所示。

2.2 实验设置

本文的所有网络模型构建、训练与推理测试均在基于 Python 的 PyTorch 深度学习框架下完成。本文实验的硬件平台是处理器 AMD Ryzen 7 9700X，运行内存 64 GB，NVIDIA GeForce RTX 5090 显卡。本文模型训练时的批处理大小（Batch Size）被设定为 16。本文模型训练时优化器采用具备优异权重衰减特性的 AdamW，模型最大训练轮次（Epochs）设定为 200 轮。训练全程采用带有预热机制的余弦退火（Cosine Annealing）学习率衰减策，其中最大学习率设定为 1×10^{-3} ，最小基础学习率设定为 1×10^{-6} 。

为提升模型对不同滑坡方向、尺度变化及局部成像差异的鲁棒性，训练阶段采用随机水平翻转、随机垂直翻转、随机旋转以及随机缩放裁剪等数据增强策略；验证与测试阶段不使用随机数

表 2 RLZX-LDD-SAT 数据集对比实验结果

Table 2 Comparative experimental results on the RLZX-LDD-SAT dataset.

模型名称	Precision(%)↑	Recall(%)↑	F1 Score(%)↑	mIoU(%)↑	参数量 (M)↓	FLOPs(G)↓	推理耗时(ms)↓
Swin-Unet	70.84	69.87	70.35	<u>74.94</u>	27.18	7.73	3.40
Unet++	69.25	71.10	70.16	74.77	9.16	34.90	3.84
UNeXt	67.48	70.84	69.12	74.05	1.47	0.57	1.42
SlideNet	65.91	71.52	68.60	73.67	117.44	32.58	5.24
DeeplabV3+	75.59	61.92	68.08	73.65	5.22	4.28	<u>1.54</u>
Trans-Unet	65.24	71.69	68.31	73.46	59.62	31.19	8.12
SABR-Net (本文算法)	<u>72.39</u>	72.29	70.87	75.23	<u>1.50</u>	<u>1.31</u>	1.62

据增强，仅进行与训练输入尺寸一致的确定性预处理，以保证评估结果的可重复性。

召回率衡量的是在所有真实的“滑坡”像素中，被模型成功找出来并正确预测的比例：

为进一步评估模型的轻量化程度与实际运行效率，本文在统一输入尺寸（1×3×256×256）下统计各模型的参数量和浮点运算次数（FLOPs），并在相同硬件平台上测试单张影像的平均推理耗时。所有模型均采用一致的输入尺寸和测试设置，以保证计算复杂度与推理效率对比的公平性。

2.3 评价指标

本实验采用了4种常用的评价指标对模型性能进行评估：精确率 (Precision)、召回率 (Recall)、F1 分数 (F1-score) 以及平均交并比 (mIoU)。

为了计算这些指标，我们首先需要基于混淆矩阵定义以下四个基础统计量：

TP (True Positive, 真阳性)：真实标签为滑坡，且被模型正确预测为滑坡的像素数量。

FP (False Positive, 假阳性)：真实标签为背景，但被模型错误预测为滑坡的像素数量（即误检）。

TN (True Negative, 真阴性)：真实标签为背景，且被模型正确预测为背景的像素数量。

FN (False Negative, 假阴性)：真实标签为滑坡，但被模型错误预测为背景的像素数量（即漏检）。

精确率 Precision 衡量的是模型所有预测为“滑坡”的像素中，真正属于滑坡像素的比例：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (12)$$

在滑坡提取任务中，Precision 越高，说明模型抵抗背景噪声干扰的能力越强，把裸土或植被误认为滑坡的情况越少（误检率低）。




图 4 滑坡提取效果对比图（RLZX-LDD-SAT 数据集）

Fig. 4. Visual comparison of landslide detection results on the RLZX-LDD-SAT dataset.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (13)$$

Recall 越高，说明模型对滑坡特征的敏感度越高，漏掉的真实滑坡区域越少（漏检率低）。

由于在正负样本不平衡的情况下，Precision 和 Recall 往往存在相互制约的博弈关系。因此，F1 分数作为两者的调和平均数，可以综合评估模型的单类别像素级分类性能：

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

交并比（IoU）是衡量预测掩膜（Prediction Mask）与真实标签（Ground Truth）之间空间几何重叠程度的终极标准。平均交并比（mIoU）则是对所有类别（本文滑坡提取任务中为“滑坡前景”与“背景”两类）的 IoU 求均值：

$$mIoU = \frac{1}{2} \left(\frac{TP}{TP + FP + FN} + \frac{TN}{TN + FN + FP} \right) \quad (15)$$

在滑坡形态复杂多变的高分辨率遥感影像中，mIoU 是最具说服力的评价指标。它不仅考验模型像素分类的对错，更严苛地考量预测的滑坡边界与真实滑坡轮廓的几何贴合度。

参数量是指深度学习网络中所有需要通过反向传播进行训练与权重更新的变量（如卷积核权重、偏置项等）的总和，通常以百万（Million，简

写为 M）为单位进行衡量。在自然灾害应急监测的实际工程应用中，参数量直接决定了模型的空间复杂度与显存占用大小。较低的参数量意味着网络更加轻量化，能够更容易地摆脱对大型地面算力服务器的依赖，从而直接部署在算力受限的边缘端侧设备上，是评估模型能否实现大范围、低延时滑坡快速响应的重要辅助指标。

浮点运算次数（Floating Point Operations, FLOPs）用于衡量模型在一次前向推理过程中所需的计算量，通常以十亿次浮点运算（Giga FLOPs, G）为单位。与参数量主要反映模型存储规模不同，FLOPs 更直接体现模型的计算复杂度。FLOPs 越低，说明模型在相同输入尺寸下所需计算开销越小，更有利于在算力受限场景中实现快速推理。

推理耗时是指模型完成单次前向预测所需的平均时间，通常以毫秒（ms）为单位。该指标能够更直观地反映模型在具体硬件平台上的实际运行效率。较低的推理耗时表明模型具有更快的响应速度，对灾害应急监测和大范围遥感影像快速处理具有重要意义。

2.4 滑坡提取实验结果

为验证本文提出的 SABR-Net 在滑坡提取任务中的有效性与优越性，我们选取了 7 种当前主流且具有代表性的深度学习模型进行对比实验。这些

对比模型涵盖了不同的网络架构设计理念，具体包括：

（1）经典卷积神经网络：Unet++（Zhou *et al.*, 2018）和 DeeplabV3+（Chen *et al.*, 2018）。

（2）基于 Transformer 的网络：Swin-Unet（Cao *et al.*, 2022）和 Segformer（Xie *et al.*, 2021）。

（3）CNN 与 Transformer 融合网络：Trans-Unet（Chen *et al.*, 2024）。

（4）轻量化与特定任务网络：UNeXt（Valanarasu *et al.*, 2022）以及 SlideNet（Bhutia *et al.*, 2026）。

所有对比模型均与本文算法在完全相同的实验环境、数据集划分比例与训练策略下进行训练与评估，以确保对比实验的绝对公平性。各对比模型在测试集上的分割精度、模型参数量、计算复杂度及推理耗时结果如表 2 所示。为直观呈现各模型的性能差异，表 2 中各项指标的最优值采用加粗表示，次优值采用下划线标出，向上（↑）或向下（↓）的箭头分别表示该指标越大越好或越小越好。

从表 2 的评估指标可以看出，本文提出的 SABR-Net 在综合性能上取得了最优的平衡。从分割精度指标可以看出，本文提出的 SABR-Net 在综合性能上取得了较优表现。SABR-Net 的 F1 Score 和 mIoU 分别达到 70.87%和 75.23%，均优于其他对比模型。虽然 DeeplabV3+在 Precision 上取得最高值，但其 Recall 相对较低，表明该模型存在一定的漏检问题；相比之下，SABR-Net 在 Precision 和 Recall 之间保持了更均衡的表现，因此获得了更高的 F1 Score 和 mIoU，说明其在滑坡区域完整提取与边界拟合方面具有较好的综合优势。从计算复杂度与推理效率指标可以看出，SABR-Net 在参数量、FLOPs、推理耗时与分割精度之间取得了较好的综合平衡。尽管其在个别效率指标上未必达到最优，但相较于 Trans-Unet、Swin-Unet 和 SlideNet 等大规模模型，SABR-Net 能够在显著降低模型规模的同时保持更高的 mIoU 和 F1 分数，说明该模型具有较好的轻量化部署潜力。

为了更直观地展示各模型的滑坡提取细节表现，图 4 给出了部分具有代表性场景的预测掩膜可视化对比结果。对比图中的红框高亮区域，可以清晰地观察到本文算法在应对复杂自然挑战时的优越性。复杂背景下的抗噪能力（如图中第 1 行

与第 3 行）：在受云雾遮挡、光照不均或存在大量相似裸土背景的区域，Unet++、UNeXt、SlideNet 和 Segformer 等模型极易受到背景光谱干扰，产生了大量的大块假阳性误报（如图中红框所示的虚假滑坡斑块）。而本文算法凭借 SGBR 模块的高层语义门控机制，成功过滤了底层特征中的光谱噪声，预测结果极为纯净，与真值图（Ground Truth）高度吻合。狭长滑坡与空间拓扑连续性（如图中第 2 行与第 4 行）：在高分辨率遥感影像中，顺着山谷倾泻的长条形滑坡往往难以提取。Swin-Unet、DeeplabV3+和 Trans-Unet 由于缺乏多尺度的自适应形态感知，在提取这类狭长滑坡时发生了严重的内部断裂或斑块化分离。本文算法受益于 SAB 模块中非对称卷积对极端长宽比特征的捕获，精准保持了长条形滑坡的空间结构完整性与连通性。在滑坡群的边缘细节处理上（如图中第 5 行），其他对比模型普遍存在边界过度平滑或锯齿化现象，且容易丢失微小的滑坡分支。本文算法不仅准确识别了滑坡的主体轮廓，其输出的边界线也更加锐利精细，几乎完全复原了真实影像中的滑坡几何形态。

2.5 消融实验

为了深入探究本文提出的 SABR-Net 模型中各个核心组件的独立贡献及其协同作用，并进一步验证联合损失函数中不同权重设置的合理性，本文在 RLZX-LDD-SAT 数据集上开展了模块消融实验与损失权重敏感性分析。首先，以轻量级 U-Net 作为基准模型，分别评估形状感知模块 SAB 与形状引导边界细化模块 SGBR 对模型性能的影响；随后，在保持网络结构、训练策略和数据划分不变的条件下，对 BCE Loss 与 Dice Loss 的不同权重组合进行对比分析。所有的消融变体模型均在相同的实验环境、超参数设置与数据增强策略下进行训练。为保证消融分析的严谨性，我们首先定义一个轻量级的标准 U-Net 作为基准模型（Baseline），并在此基础上构建了四种不同的网络变体进行全面对比：

（1）Baseline（基准模型）：剥离本文提出的所有创新模块。在特征提取阶段仅使用标准的卷积块；在跨层融合阶段（跳跃连接），直接将低层特征与高层特征在通道维度上进行普通的特征拼接。（2）Variant 1（基准+ASPP）：为了证明 SAB 模块设计的优越性，本变体模型不在网络

表 3 SABR-Net 模型消融实验结果

Table 3 Ablation results for SABR-Net.

模型变体	SAB	SGBR	Precision (%) ↑	Recall (%) ↑	F1 Score (%) ↑	mIoU (%) ↑	参数量 (M) ↓
Baseline	×	×	66.12	61.50	64.26	68.15	1.12
Variant 1	ASPP	×	69.45	67.80	68.61	70.30	2.56
Variant 2	✓	×	<u>71.80</u>	<u>70.10</u>	<u>69.94</u>	<u>73.85</u>	1.48
Variant 3	×	✓	70.05	68.50	69.15	72.50	1.14
SABR-Net	✓	✓	72.39	72.29	70.87	75.23	<u>1.50</u>

表 4 不同损失权重组合敏感性分析结果

Table 4 Sensitivity analysis results under different loss weight combinations.

λ_1 (BCE Loss)	λ_2 (Dice Loss)	Precision(%)↑	Recall(%)↑	F1 Score(%)↑	mIoU(%)↑
0.5	1.0	70.68	<u>72.64</u>	70.31	74.36
1.0	0.5	<u>73.05</u>	68.41	69.38	73.92
1.0	1.0	72.39	72.29	70.87	75.23
1.0	1.5	71.20	73.15	<u>70.56</u>	<u>74.85</u>
1.5	1.0	73.42	69.77	70.16	74.45

中加入 SAB，而是引入最经典的空洞空间金字塔池化模块（ASPP）作为多尺度特征提取器（Chen *et al.*, 2017）。

（3）Variant 2（仅含 SAB）：在基准模型的基础上，仅在编码器和解码器的特征流转节点加入形状感知模块（SAB），跨层融合仍保持普通的特征拼接。

（4）Variant 3（仅含 SGBR）：在基准模型的基础上，仅在跨层融合阶段引入形状引导边界细化模块（SGBR），以高层语义作为门控过滤低层特征，但不使用 SAB 进行形态感知。

（5）SABR-Net：本文最终提出的完整网络架构，同时结合了 SAB 与 SGBR 模块。各模型变体的定量评估指标如表 3 所示。

对比 Baseline 与 Variant 2 可以发现，引入 SAB 模块后，模型的召回率（Recall）实现了显著提升（从 61.50% 跃升至 70.10%）。这有力地证明了 SAB 模块内部的异构大核卷积能够有效地自适应滑坡极端的长宽比特征。传统的卷积局部感受野极易导致长条形滑坡在预测中发生断裂，而 SAB 模块通过建立更广阔的空间上下文，成功召回了那些形态狭长或宏观面积巨大的滑坡主体。此外，通过对比 Variant1(ASPP)与 Variant2(SAB) 可以看出，虽然经典的 ASPP 模块也能通过空洞卷积捕获多尺度信息，但其采用的对称膨胀方式并不契合滑坡强方向性的几何形态。SAB 模块不仅在 mIoU 上超越了 ASPP（提升了 3.55%），且由于采用了深度可分离卷积，其参数量仅为 ASPP 变体的一半

左右，充分彰显了该模块在高效性与针对性上的双重优势。Baseline 与 Variant 3 可以观察到，单独引入 SGBR 模块对精确率（Precision）的提升最为明显（相比基准模型提升了 3.93%）。在传统的跨层融合中，低层特征携带的大量光谱噪声（如光谱与滑坡极度相似的裸土和稀疏植被）被无差别地送入解码层，极易导致严重的假阳性误检。SGBR 模块将高层语义特征转化为软门控（Soft Gate），对低层特征进行像素级的精准屏蔽。这一机制从根本上切断了背景噪声向上传递的路径，使得预测出的滑坡边界更加干净、锐利，大幅降低了将周边复杂地物误判为滑坡的概率。当 SAB 与 SGBR 被同时集成到最终的 SABR-Net 中时，模型在各项指标上均达到了峰值水平（mIoU 高达 75.23%）。SAB 模块侧重于宏观全局形态的完整召回，而 SGBR 模块则致力于微观局部边界的抗噪与锐化。两者在特征流转的前端与后端形成了一种完美的互补关系，在仅仅增加了极少参数量（总参数量仅为 1.50M）的前提下，实现了模型对复杂自然场景下滑坡提取性能的全面提升。

为进一步验证 BCE Loss 与 Dice Loss 权重设置的合理性，本文在保持网络结构、训练策略和数据划分不变的条件下，对不同 λ_1 与 λ_2 组合进行了敏感性分析，结果如表 X 所示。可以看出，当 $\lambda_1 = 1.0$ 、 $\lambda_2 = 1.0$ 时，模型在 Precision、Recall、F1 Score 和 mIoU 之间取得了较为均衡的表现。适当提高 Dice Loss 权重有助于增强模型对滑坡前景区域的关注，但过高的 Dice 权重可能削弱像素级

分类约束，导致误检增加；相反，过高的 BCE Loss 权重则可能使模型更偏向背景像素判别，不利于小面积或狭长滑坡区域的完整召回。因此，本文最终采用 $\lambda_1 = 1.0$ 、 $\lambda_2 = 1.0$ 作为默认设置。

2.6 不足之处

尽管本文提出的 SABR-Net 在 RLZX-LDD-SAT 数据集上取得了优异的提取精度与极致的轻量化表现，但由于自然场景的极端复杂性与硬件感知手段的物理限制，本研究仍存在以下局限性，这也为未来的研究指明了方向：1. 光学遥感影像的天然局限性与多源传感器融合的缺失。本实验主要依赖于高分卫星（Gaofen）的光学遥感影像。然而，降雨诱发型滑坡通常伴随极端的强降水与恶劣气象，灾后初期灾区上空往往被厚重的云层和浓雾覆盖，导致高质量光学影像的获取面临极大的滞后性。虽然网络对云影噪声有一定的鲁棒性，但光学传感器无法穿透云层和茂密植被冠层。未来研究可考虑引入合成孔径雷达（SAR）数据，利用其全天候、穿透性强的物理优势，与本文模型进行多模态融合，以实现更具时效性的应急滑坡监测。2. 对极微小滑坡体的感知能力受限。RLZX-LDD-SAT 数据集中的滑坡面积跨度极大，最小的滑坡单体面积仅为 $4m^2$ 。在空间分辨率为2m的卫星影像中，这类极微小滑坡仅占据1到2个像素。尽管本文的形状感知模块（SAB）和边界细化模块（SGBR）在维持中大型狭长滑坡连通性方面表现卓越，但在经典的编码器-解码器下采样过程中，这种单像素级别的微弱空间特征仍不可避免地会发生一定程度的丢失。如何在大幅增加网络参数数量的同时，是下一步亟待突破的难题。3. 跨区域与跨诱发机制的泛化验证仍需拓展。本文模型是基于中国南方植被覆盖茂密山区的降雨诱发型滑坡群进行训练与评估的。在此类场景中，滑坡导致了植被的显著剥离，形成了强烈的光谱对比。然而，对于干旱黄土高原地区的地震诱发型滑坡（如黄土滑坡），其裸露滑坡体与周围背景环境的光谱差异极小，且滑动机制与空间形态与降雨型滑坡存在本质区别。因此，SABR-Net 在跨地质构造、跨气候带以及跨诱发机制（降雨与地震）下的领域泛化能力，仍需要未来在更大规模的全球异构数据集上进行更深度的迁移学习与测试验证。

3 结论

针对高分辨率遥感影像中滑坡几何形态极端多变（如狭长条带或大范围崩塌），以及复杂背景光谱噪声（裸土、稀疏植被）极易导致预测边界锯齿化和假阳性误检的难题，本文提出了一种全新的轻量级滑坡形状感知与边界细化网络 SABR-Net。本文的核心贡献在于对传统编码器-解码器架构进行了深度重构：一方面，提出了形状感知模块（SAB），通过巧妙引入多分支异构卷积与动态自适应加权，极大增强了模型对多尺度和极端长宽比形态先验的捕捉能力，有效解决了长条形滑坡内部断裂的痛点；另一方面，设计了形状引导边界细化模块（SGBR），创新性地利用高层语义特征作为软门控，对底层高分辨率特征进行像素级空间过滤，从根本上切断了背景噪声向解码层传递的路径，实现了滑坡轮廓的锐化与精细还原。基于最新发布的资兴极端降雨诱发滑坡数据集（RLZX-LDD-SAT）的广泛实验与消融分析表明，SABR-Net 在应对正负样本极度不平衡与复杂自然背景干扰时展现出了卓越的鲁棒性。与 Swin-Unet、DeeplabV3+、Segformer、SlideNet 等 7 种当前主流的深度学习模型相比，SABR-Net 仅需极其微小的 1.50M 参数量，便取得了最高的 75.23% 平均交并比和 70.87% 的 F1 分数。总而言之，SABR-Net 在提取精度与计算复杂度之间取得了较好的平衡。它不仅为基于多源遥感影像的滑坡提取提供了一种高效、精准的深度学习新方法，其轻量化特性也为未来在地质灾害应急响应中的端侧硬件部署（如无人机机载处理平台、星载边缘计算终端）奠定了坚实的工程基础。未来，我们将致力于引入合成孔径雷达（SAR）等多模态数据源，进一步提升模型在极端气象条件与跨区域场景下的泛化监测能力。

References

- Amankwah, S. O. Y., Wang, G.J., Gnyawali K., et al., 2022. Landslide Detection from Bitemporal Satellite Imagery Using Attention-based Deep Neural Networks. *Landslides*, 19(10): 2459-2471. <https://doi.org/10.1007/s10346-022-01930-7>
- Bhutia S.L., Borah S., Sharma A.L., et al., 2026. Slidenet: A Wavelet-Enhanced Architecture for Landslide Segmentation. *The Visual Computer*, 42(1): 64. <https://doi.org/10.1007/s00371-025-04301-0>
- Chen L.C., Papandreou G., Kokkinos I., et al., 2017. Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected Crfs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,

- 40(4): 834-848.
<https://doi.org/10.1109/TPAMI.2017.2699184>
- Chen, L.C., Zhu Y.K., Papandreou G., et al., 2018. Encoder-Decoder with Atrous Separable Convolution For Semantic Image Segmentation. In *Proceedings of The European Conference on Computer Vision*: 801-818.
https://doi.org/10.1007/978-3-030-01234-2_49
- Cao, H., Wang Y.Y., Chen J., et al., 2022. Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation. In *Proceedings of European Conference on Computer Vision*. Cham: Springer Nature Switzerland, 2022: 205-218.
https://doi.org/10.1007/978-3-031-25066-8_9
- Chen, H.S., He, Y., Zhang, L.F., et al., 2023. A Landslide Extraction Method of Channel Attention Mechanism U-Net Network Based on Sentinel-2A Remote Sensing Images. *International Journal of Digital Earth*, 16(1): 552-577.
<https://doi.org/10.1080/17538947.2023.2177359>
- Chen, J.N., Mei, J.R., Li, X.H., et al., 2024. TransUNet: Rethinking the U-Net Architecture Design for Medical Image Segmentation Through The Lens of Transformers. *Medical Image Analysis*, 97: 103280.
<https://doi.org/10.1016/j.media.2024.103280>
- Chandra N., Vaidya H., Abhinav K., et al., 2025. Global Landslide Mapping Using U-Net Architecture with Diverse Backbones Across Multi-Regional and Multi-Sensor Remote Sensing Datasets. *Frontiers in Earth Science*, 13: 1710586. <https://doi.org/10.3389/feart.2025.1710586>
- Du, C.L. , Qi, S.Q., Wan, L.H., et al.,2026. GCF-Net: A Geometric Context and Frequency Domain Fusion Network for Landslide Segmentation in Remote Sensing Imagery. *Remote Sensing*, 18(4): 635.
<https://doi.org/10.3390/rs18040635>
- Fu, Z., Wang, F., Ma, H. et al., 2025. Records of Shallow Landslides Triggered By Extreme Rainfall in July 2024 in Zixing, China. *Scientific Data* 12, 1364.
<https://doi.org/10.1038/s41597-025-05670-w>
- Ghorbanzadeh O., Blaschke T., Gholamnia K., et al., 2019. Evaluation of Different Machine Learning Methods and Deep-Learning Convolutional Neural Networks for Landslide Detection. *Remote Sensing*, 11(2): 196.
<https://doi.org/10.3390/rs11020196>
- Han, Z., Fang, Z.X., Li, Y., et al., 2023. A Novel Dynahead-Yolo Neural Network for The Detection of Landslides with Variable Proportions Using Remote Sensing Images. *Frontiers in Earth Science*, 10: 1077153.
<https://doi.org/10.3389/feart.2022.1077153>
- 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. <https://doi.org/10.3390/rs14071552>
- Lin, T.Y., Goyal P., Girshick R., et al., 2020. Focal Loss for Dense Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2): 318-327.
<https://doi.org/10.1109/TPAMI.2018.2858826>
- Milletari F., Navab N., Ahmadi S. A., 2016. V-net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. In *Fourth International Conference on 3D Vision*. <https://doi.org/10.1109/3DV.2016.79> 565-571.
- Ronneberger O., Fischer P., Brox T., 2015. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*. 234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- Ren, S.Q., He, K.M., Girshick, R., et al, 2016. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149.
<https://doi.org/10.1109/TPAMI.2016.2577031>
- Redmon J., Divvala S., Girshick R., et al., 2016. You Only Look Once: Unified, Real-Time Object Detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*:779-788.
<https://doi.org/10.1109/CVPR.2016.91>
- Valanarasu J.M.J., Patel V.M., 2022. Unext: Mlp-based Rapid Medical Image Segmentation Network. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer Nature Switzerland, 2022: 23-33. https://doi.org/10.1007/978-3-031-16443-9_3
- Xie, E.Z., Wang, W.H., Yu, Z.D., et al., 2021. SegFormer: Simple and Efficient Design for Semantic Segmentation With Transformers. In *Proceedings of the 35th International Conference on Neural Information Processing Systems*:12077-12090.
- Zhao, W., Li, A., 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.
<https://doi.org/10.1109/JSTARS.2017.2661802>
- Zhou, Z.W., Rahman Siddiquee M.M, Tajbakhsh N., et al., 2018. Unet++: A Nested U-Net Architecture for Medical Image Segmentation. In *International Workshop On Deep Learning in Medical Image Analysis*: 3-11.
https://doi.org/10.1007/978-3-030-00889-5_1
- Zhang, C., Luo, J., Li, Z., 2025. An Automatic Detection Method of Slow-Moving Landslides Using An Improved Faster R-CNN Model Based on InSAR Deformation Rates. *Remote Sensing*, 17(18): 3243.
<https://doi.org/10.3390/rs17183243>

中文参考文献

- 张圻恺, 凌斯祥, 李晓宁, 等. 九寨沟县滑坡灾害易发性快速评估模型对比研究. 岩石力学与工程学报, 2020, 39(8): 1595-1610.
- 陈文鸿, 余斌, 叶鹏, 等. 浅层滑坡诱发沟谷型泥石流的物源条件. 地球科学, 2025, 50(6): 2356-2371.
- 李振洪, 张成龙, 陈博, 等. 一种基于多源遥感的滑坡防灾技术框架及其工程应用. 地球科学, 2022, 47(6): 1901-1916.

- 许强. 对地质灾害隐患早期识别相关问题的认识与思考. 武汉大学学报(信息科学版), 2020, 45(11):1651-1659.
- 钟洪星, 巨袁臻, 王赟, 等. 基于迁移学习的水库滑坡自动识别研究. 人民长江, 2025, 56(S1):170-175.
- 吴润泽, 胡旭东, 梅红波, 等. 基于随机森林的滑坡空间易发性评价: 以三峡库区湖北段为例. 地球科学, 2021, 46(1): 321-330.
- 毛正君, 李欢, 石硕杰, 等. 面向对象的无人机遥感影像区域滑坡承灾体信息提取研究. 工程地质学报, 2025, 33(1):171-185.
- 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. 自然资源遥感, 2022, 34(02):224-230.
- 侯梦媛, 李明亮, 吕梅洁. 基于遥感影像的滑坡图像检测方法的研究. 计算机科学与应用, 2023, 13(11):2051-2061.
- 张灿灿, 丁明涛, 申传庆, 等. 基于 MultiU-EGANet 模型的同震滑坡智能识别. 地球科学, 2025, 50(08):3182-3198.
- 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. 地球信息科学学报, 2023, 25(10):2012-2025.
- 赵通, 张双成, 何晓宁, 等. 改进的 DeepLabV3+模型用于震后高分遥感影像滑坡识别. 遥感学报, 2024, 28(9): 2293-2305.