

# 基于深度学习的滑坡目标检测模型对比研究

郑智鹏

云南师范大学地理学部, 云南 昆明

收稿日期: 2026年4月7日; 录用日期: 2026年6月16日; 发布日期: 2026年6月26日

## 摘要

针对滑坡目标识别中人工解译效率低、复杂场景下目标检测效果不稳定等问题, 本文基于公开滑坡目标检测数据集, 选取YOLOv8、YOLOv11和RT-DETR三种目标检测模型开展对比实验, 对不同模型在滑坡识别任务中的性能进行分析。实验采用统一数据集和训练条件, 从模型训练过程、验证集定量指标以及可视化检测结果三个方面进行评价。结果表明, 三种模型均能够较好地完成滑坡目标检测任务, 训练过程中损失函数整体下降, 精确率(Precision,  $P$ )、召回率(Recall,  $R$ )和平均精度均值(mean Average Precision, mAP)等指标持续提升并趋于稳定, 表现出较好的收敛性。其中, RT-DETR的综合检测性能最好, 其Precision、Recall、mAP@0.5和mAP@0.5:0.95分别达到0.954、0.950、0.964和0.815, 均优于YOLOv8和YOLOv11, 说明其在滑坡目标识别和边界框定位方面具有更高精度。可视化结果进一步表明, RT-DETR的检测框完整性和稳定性最好, YOLOv11次之, YOLOv8在个别复杂场景下存在重复检测现象。研究表明, 三种模型均适用于滑坡目标检测任务, 其中RT-DETR更适合精度要求较高的场景, YOLOv11更适合兼顾检测效果与实时性的应用需求。

## 关键词

滑坡检测, 目标检测, YOLOv8, YOLOv11, RT-DETR, 深度学习

# Comparative Study of Deep Learning Models for Landslide Object Detection

Zhipeng Zheng

Faculty of Geography, Yunnan Normal University, Kunming Yunnan

Received: April 7, 2026; accepted: June 16, 2026; published: June 26, 2026

## Abstract

To address the problems of low efficiency in manual interpretation and unstable detection performance in complex landslide scenes, this study conducted comparative experiments using three

object detection models, namely YOLOv8, YOLOv11, and RT-DETR, based on a public landslide object detection dataset, and analyzed their performance in landslide recognition tasks. Under the same dataset and training conditions, the models were evaluated from three aspects: the training process, quantitative validation metrics, and visualization of detection results. The results show that all three models can effectively accomplish landslide object detection. During training, the loss functions generally decreased, while indicators such as Precision ( $P$ ), Recall ( $R$ ), and mean Average Precision (mAP) continuously improved and gradually stabilized, indicating good convergence. Among them, RT-DETR achieved the best overall detection performance, with Precision, Recall, mAP@0.5, and mAP@0.5:0.95 reaching 0.954, 0.950, 0.964, and 0.815, respectively, all higher than those of YOLOv8 and YOLOv11, demonstrating higher accuracy in landslide recognition and bounding box localization. The visualization results further show that RT-DETR achieved the best completeness and stability of detection boxes, followed by YOLOv11, while YOLOv8 showed repeated detections in some complex scenes. The study indicates that all three models are suitable for landslide object detection tasks. RT-DETR is more suitable for scenarios requiring higher accuracy, while YOLOv11 is more appropriate for applications that need to balance detection performance and real-time efficiency.

## Keywords

Landslide Detection, Object Detection, YOLOv8, YOLOv11, RT-DETR, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

滑坡是山地地区常见的地质灾害类型之一, 具有突发性强、破坏范围广和危害程度高等特点, 常对道路交通、工程设施和居民生命财产安全造成严重威胁[1]-[3]。特别是在山区公路沿线、边坡和护坡等区域, 受降雨、地形条件及人为扰动等因素影响, 滑坡灾害发生频率较高。因此, 如何快速、准确地识别滑坡区域, 一直是地质灾害监测与风险控制中的重要问题。

传统滑坡识别方法主要依赖人工解译、现场调查和经验判读, 不仅工作量大、效率较低, 而且容易受到主观因素影响, 难以满足大规模、多场景条件下的快速识别需求[4] [5]。随着遥感影像和计算机视觉技术的发展, 基于深度学习的目标检测方法在图像识别领域取得了较好效果, 也为滑坡自动识别提供了新的技术手段[6]。与传统方法相比, 目标检测模型能够直接从图像中提取特征并定位目标区域, 在识别效率和自动化程度方面具有明显优势[7]。

目前, You Only Look Once (YOLO)系列模型因检测速度快、结构简洁、部署方便, 已在多种目标检测任务中得到广泛应用[8] [9]。其中, YOLOv8 作为较为成熟的单阶段检测模型, 在精度和速度之间具有较好的平衡[10]; YOLOv11 在特征提取和特征融合方面进行了优化, 进一步提升了模型性能[11]。除此之外, Real-Time Detection Transformer (RT-DETR)作为一种实时目标检测模型, 在网络中引入了 Transformer 结构相关思想, 具备较强的全局特征建模能力, 也在目标检测任务中表现出较好的应用潜力[12] [13]。尽管上述模型均具有一定优势, 但在滑坡目标检测这一具体任务中, 不同模型在检测精度、召回能力、运行效率和复杂场景适应性等方面仍可能存在差异。

滑坡图像通常具有目标形态不规则、尺度变化较大、背景干扰较强等特点, 这给目标检测模型的识别能力提出了更高要求[14]。因此, 有必要基于统一数据集和统一实验条件, 对不同主流目标检测模型在

滑坡识别任务中的表现进行对比分析,以明确各模型的优势与适用场景。基于此,本文采用公开滑坡目标检测数据集,选取 YOLOv8、YOLOv11 和 RT-DETR 三种模型开展对比实验,并从模型训练过程、验证指标和可视化检测结果三个方面对其性能进行分析。研究结果可为滑坡目标检测模型的选择和应用提供参考。

## 2. 数据与方法

### 2.1. 数据集

本文实验数据来源于网络公开分享的滑坡目标检测数据集,如图 1 所示。该数据集主要面向山坡、边坡及护坡等场景下的滑坡目标检测,包含 6600 余张  $640 \times 640$  的已标注图像,覆盖不同天气和光照条件,具有一定的场景复杂性和目标差异性,可用于目标检测模型的训练、验证与测试。数据集按 9:1 划分为训练集和验证集。其中,训练集用于模型训练,验证集用于参数调优与模型选择。基于该数据集,本文选取 YOLOv8、YOLOv11 和 RT-DETR 三种目标检测模型开展对比实验,以分析不同模型在滑坡目标检测任务中的性能差异。数据集来源 <https://www.youluoyuan.com/1139.html>。



Figure 1. Example images of the landslide object detection dataset

图 1. 滑坡目标检测数据集示例

### 2.2. 实验模型

#### 2.2.1. YOLOv8 模型

YOLOv8 是一种单阶段目标检测模型,具有检测速度快、结构简洁和部署方便等特点,已在多种目标检测任务中得到广泛应用。其网络结构主要由主干网络、颈部网络和检测头三部分组成,如图 2 所示。

在主干网络部分,YOLOv8 以卷积模块(Conv)和 C2f 模块为核心,对输入图像进行逐层特征提取。卷积模块主要用于完成特征图的下采样和通道变换,C2f 模块则通过更充分的特征分支连接与信息融合,

提高了特征表达能力，同时兼顾了模型的计算效率[15]。主干网络末端引入 SPPF 模块，通过不同尺度感受野的信息聚合，进一步增强了网络对目标空间上下文信息的提取能力。

在颈部网络部分, YOLOv8 采用自顶向下与自底向上的多尺度特征融合方式, 通过上采样(Upsample)、特征拼接(Concat)以及 C2f 模块, 对不同层级的特征信息进行融合, 从而兼顾高层语义信息与低层细节信息。该结构有利于提升模型对不同尺度目标的检测能力。检测头部分设置了三个尺度的输出分支, 分别对不同尺度目标进行预测, 从而提高模型对小目标、中目标和大目标的识别效果。

YOLOv8网络结构图

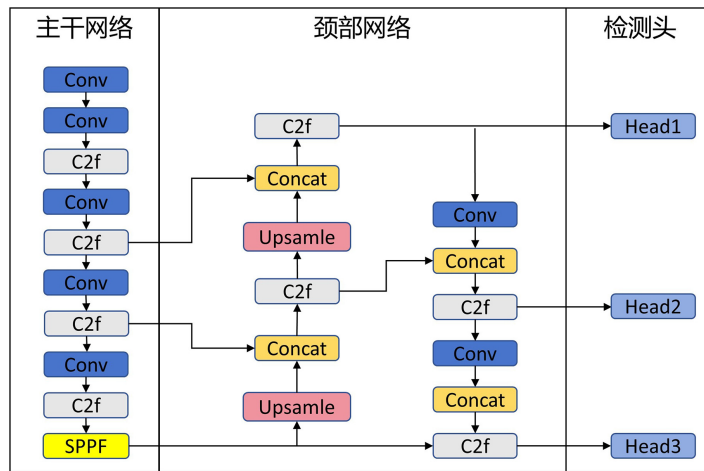


Figure 2. Network architecture of the YOLOv8 model  
图 2. YOLOv8 模型网络结构

### 2.2.2. YOLOv11 模型

YOLOv11 同样属于单阶段目标检测模型, 其总体结构仍由主干网络、颈部网络和检测头构成, 但在特征提取与特征融合模块上进行了优化, 如图 3 所示。

YOLOv11网络结构图

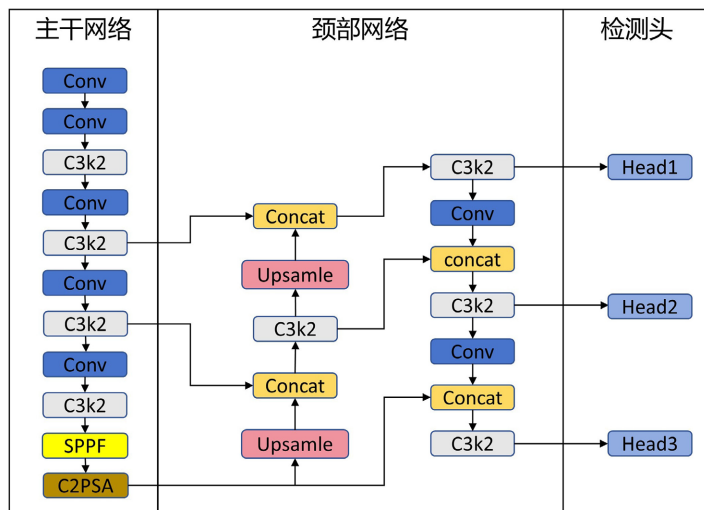


Figure 3. Network architecture of the YOLOv11 model  
图 3. YOLOv11 模型网络结构

在主干网络中, YOLOv11 主要由卷积模块、C3k2 模块、SPPF 模块和 C2PSA 模块组成。卷积模块用于完成基础特征提取与下采样; C3k2 模块在保持网络表达能力的同时, 有助于提高特征提取效率; SPPF 模块用于扩大感受野, 增强网络对多尺度空间信息的建模能力; 在主干网络末端加入的 C2PSA 模块进一步强化了网络对关键区域特征的关注能力, 有助于提升复杂背景下目标特征的表达效果[16]。

在颈部网络中, YOLOv11 仍采用多尺度特征融合策略, 通过上采样与特征拼接操作, 将不同层级的特征图进行融合, 并结合 C3k2 模块进一步提炼融合后的特征信息。检测头部分输出三个尺度的检测结果, 以适应不同尺寸目标的识别需求。相较于传统 YOLO 结构, YOLOv11 在保持较高检测效率的基础上, 更强调特征提取与显著信息表达, 对复杂场景中的目标检测具有较好的适应性[17]。

### 2.2.3. RT-DETR 模型

RT-DETR 是一种实时目标检测模型, 其结构主要包括主干网络、编码器和解码器三部分, 如图 4 所示。与 YOLO 系列模型相比, RT-DETR 在网络中引入了 Transformer 相关思想, 因此在全局特征建模方面具有一定特点[18]。

在主干网络部分, RT-DETR 通过 ConvNormLayer、MaxPool2d 和 BasicBlocks 等模块对输入图像进行特征提取, 得到不同层次的特征图。随后, 这些特征被送入编码器进行进一步处理。编码器部分通过卷积、上采样、特征拼接和 RepC3 等操作, 对不同尺度的特征进行融合, 从而增强模型对目标信息的表达能力[19]。

在解码器部分, RT-DETR 利用基于交并比(Intersection over Union, IoU)的查询选择机制(IoU-aware Query Selection)筛选出更有代表性的查询信息, 再通过解码器和检测头输出最终的检测结果。相比于传统卷积检测模型, RT-DETR 能够更好地利用图像中的整体信息, 对复杂场景下的目标识别具有一定优势[20]。

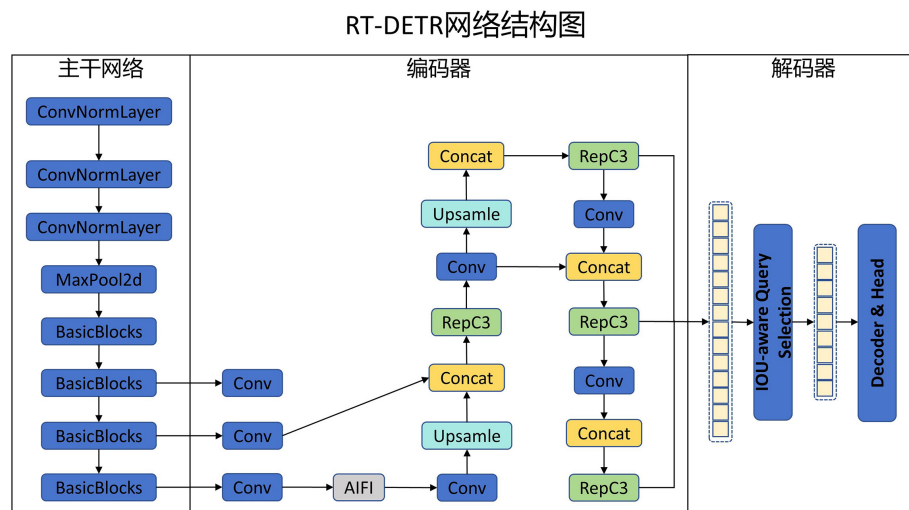


Figure 4. Network architecture of the RT-DETR model

图 4. RT-DETR 模型网络结构

## 2.3. 评价指标

为全面评估模型在滑坡目标检测任务中的性能, 本文采用目标检测领域常用的评价指标, 包括精确率(Precision,  $P$ )、召回率(Recall,  $R$ )和平均精度均值(mean Average Precision, mAP)。

精确率( $P$ )表示预测为正的样本中实际为正的比例,即预测为滑坡的目标中实际为滑坡的比例。

$$P = \frac{TP}{TP + FP} \quad (1)$$

召回率( $R$ )表示真正样本中被正确预测的比例,即所有真实滑坡目标中被正确检测出来的比例。

$$R = \frac{TP}{TP + FN} \quad (2)$$

平均精度均值(mAP)是综合评价目标检测性能的重要指标,用于衡量模型在不同交并比(Intersection over Union, IoU)阈值下的检测准确性。本文主要采用 mAP@0.5 和 mAP@0.5:0.95 对模型性能进行评价。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

其中,  $TP$  为正确检测为滑坡的数量,  $FP$  为误检为滑坡的数量,  $FN$  表示漏检的滑坡的数量,  $N$  为类别的数量,  $AP_i$  为第  $i$  类的平均精度。

### 3. 实验结果与分析

#### 3.1. 实验环境

实验环境如下:操作系统为 Windows 11,编程语言为 Python,深度学习框架为 PyTorch。硬件设备包括 Intel (R) Xeon (R) Gold 6226R CPU @ 2.90 GHz、256 GB RAM 和 NVIDIA RTX A6000 显卡(48 GB 显存)。数据增强的参数统一设置为 HSV 颜色空间扰动,其中色调、饱和度和亮度扰动系数分别设置为 0.015、0.7 和 0.4;几何变换方面,旋转角度设为 0.0,平移幅度设为 0.1,缩放系数设为 0.5,错切和透视变换均设为 0.0;翻转增强方面,垂直翻转概率设为 0.0,水平翻转概率设为 0.5。模型训练的超参数如下表 1:

**Table 1.** Experimental parameter settings for different models

**表 1.** 不同模型实验参数设置


| 模型      | 训练轮数 | 批次 | 输入尺寸 | 优化器   | 学习率  | 权重衰减  |
|---------|------|----|------|-------|------|-------|
| YOLOv8  | 200  | 64 | 640  | SGD   | 0.01 | 0.005 |
| YOLOv11 | 200  | 64 | 640  | SGD   | 0.01 | 0.005 |
| RT-DETR | 200  | 64 | 640  | AdamW | 0.01 | 0.001 |

#### 3.2. 模型训练过程分析

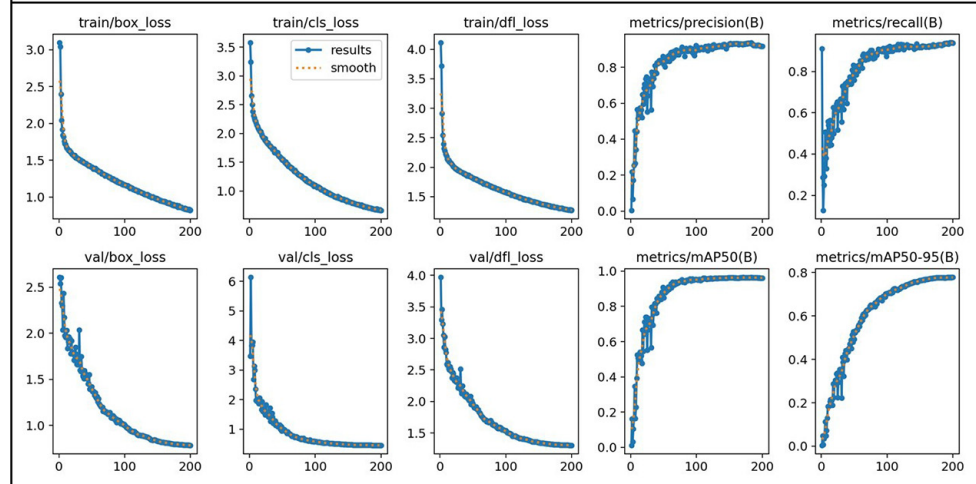
为比较 YOLOv8、YOLOv11 和 RT-DETR 在滑坡目标检测任务中的训练效果,本文绘制了三种模型训练过程中的损失函数和评价指标变化曲线,如图 5 所示。总体来看,随着训练轮次增加,三种模型的训练损失和验证损失均逐渐下降, Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 等指标不断上升并在后期趋于稳定,说明三种模型均能够较好地学习滑坡目标特征,训练过程整体较为稳定。

其中, YOLOv8 的各项损失下降较为平稳,评价指标提升较快,表明该模型在本数据集上具有较好的收敛性。YOLOv11 的整体变化趋势与 YOLOv8 基本一致,虽然训练前期存在一定波动,但中后期逐渐稳定,说明其同样能够较好地适应该数据集。RT-DETR 在训练初期的波动相对更明显,但随着训练进行,各项损失持续下降,评价指标逐步提高并保持稳定,最终也表现出良好的收敛效果。

YOLOv8



YOLOv11



RT-DETR

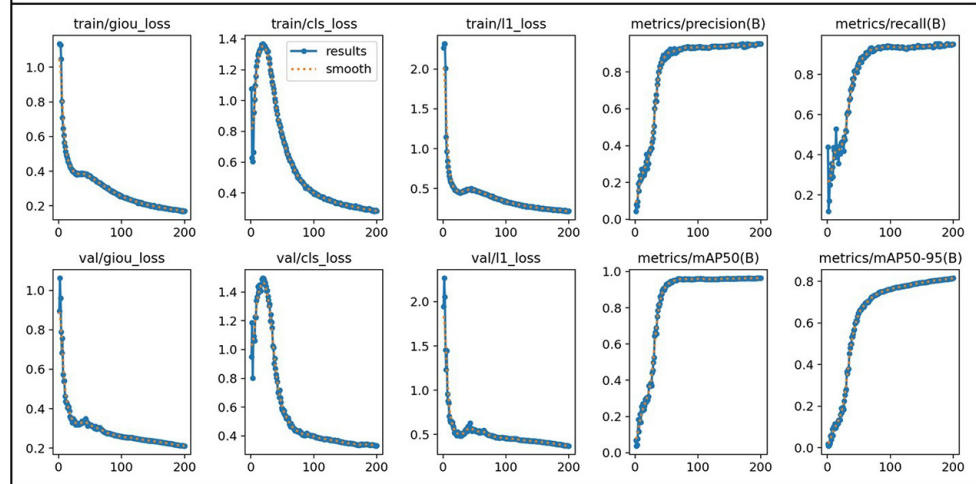


Figure 5. Training curves of the three models

图 5. 三种模型训练过程曲线

### 3.3. 不同模型验证结果对比

表 2 给出了三个模型在验证集上的检测结果。总体来看，YOLOv8、YOLOv11 和 RT-DETR 三种模

型均能够较好地完成滑坡目标检测任务，各项指标整体较高，说明基于深度学习的目标检测方法在该数据集上具有较好的适用性。但不同模型在检测精度和召回能力方面仍表现出一定差异。

在检测精度方面，RT-DETR 的综合表现最优，其  $P$ 、 $R$ 、 $mAP@0.5$ 、 $mAP@0.5:0.95$  均为三种模型中的最高值。这表明 RT-DETR 在滑坡目标检测与边界框定位方面具有更强的能力，尤其在更严格的评价指标  $mAP@0.5:0.95$  上优势更为明显，说明其整体检测质量更高。

YOLOv11 与 YOLOv8 的检测结果较为接近。YOLOv11 的  $R$ 、 $mAP@0.5$  和  $mAP@0.5:0.95$  略高于 YOLOv8，说明其在目标检出率和总体检测效果上略占优势。然而，YOLOv8 的  $P$  高于 YOLOv11，表明 YOLOv8 在部分样本上的定位结果更为稳定。

**Table 2.** Comparison of validation results of different models


**表 2.** 不同模型验证结果对比

| 模型      | $P$   | $R$   | $mAP@0.5$ | $mAP@0.5:0.95$ |
|---------|-------|-------|-----------|----------------|
| YOLOv8  | 0.929 | 0.933 | 0.956     | 0.776          |
| YOLOv11 | 0.917 | 0.938 | 0.961     | 0.778          |
| RT-DETR | 0.954 | 0.950 | 0.964     | 0.815          |

### 3.4. 可视化检测结果分析

为更直观地比较不同模型在滑坡目标检测任务中的实际表现，本文选取 6 组典型样本，对 YOLOv8、YOLOv11 和 RT-DETR 的检测结果进行可视化展示，如图 6~8 所示。总体来看，三种模型均能够识别出图像中的主要滑坡区域，但在检测框完整性、置信度以及复杂场景下的检测稳定性方面仍存在一定差异。

从图 8 中可以看出，RT-DETR 在 6 组样本中均给出了较为完整的检测结果，检测框与滑坡区域的贴合程度较高，且整体置信度较高，说明该模型对滑坡目标的识别能力较强，在复杂背景下仍具有较好的稳定性。尤其是在图 6 中 b、c、d、e 等场景下，RT-DETR 对滑坡范围的覆盖较完整，检测结果与实际目标区域较为一致，表现出较好的综合检测效果。



**Figure 6.** Visualization of detection results of the YOLOv8 model

**图 6.** YOLOv8 模型检测结果可视化

YOLOv11 的检测结果整体也较为稳定，能够较好识别大部分滑坡区域，但部分样本的检测置信度相对偏低，且个别检测框对滑坡边界的覆盖不如 RT-DETR 完整。例如在图 7 的 b、c、d、e 等图像中，YOLOv11 虽然能够正确检测目标，但检测框尺度和位置仍存在一定偏差，说明其在复杂场景中的目标定位能力还有提升空间。




Figure 7. Visualization of detection results of the YOLOv11 model  
图 7. YOLOv11 模型检测结果可视化




Figure 8. Visualization of detection results of the RT-DETR model  
图 8. RT-DETR 模型检测结果可视化

YOLOv8 在多数样本中同样能够实现滑坡目标检测，但在部分复杂场景下出现了重复检测或局部框选不够准确的现象。特别是在图 6 的 d 图中，YOLOv8 对同一滑坡区域给出了多个检测框，且部分检测框置信度较低，说明该模型在面对大范围滑坡或边界较复杂目标时，容易出现目标分割不充分或重复响应的问题。相比之下，其余样本中的检测结果仍较为正常，表明 YOLOv8 具有一定的检测能力，但整体

稳定性略逊于 RT-DETR。

综合可视化结果来看，RT-DETR 在目标完整性、定位准确性和检测稳定性方面表现最好，YOLOv11 次之，YOLOv8 在部分复杂样本上存在重复检测现象。这一结果与前文验证指标的对比结论基本一致，进一步说明 RT-DETR 在该滑坡数据集上具有更好的综合检测性能。

### 3.5. 计算效率分析

为全面评估不同模型的应用性能，本文在统一硬件环境下对三种模型的计算效率进行了测试。结果如表 3，YOLOv8、YOLOv11 和 RT-DETR 的参数量分别为 3.01 M、2.58 M 和 19.87 M，对应计算量分别为 8.1 GFLOPs、6.3 GFLOPs 和 56.9 GFLOPs；其平均单张推理时延分别为 12.93 ms、16.48 ms 和 33.19 ms，对应 FPS 分别为 77.4、60.7 和 30.1。整体来看，YOLOv8 在三种模型中具有最佳的实时性表现，而 RT-DETR 的模型复杂度和计算开销最大。值得注意的是，YOLOv11 虽然在参数量和计算量上均低于 YOLOv8，但其推理速度并未更快，说明模型运行效率不仅与模型规模有关，还受到网络结构与硬件执行效率等因素的共同影响。

**Table 3.** Comparison table of computational efficiency

**表 3.** 计算效率对比表

| 模型      | 参数量   | 单张推理时间 | FPS  |
|---------|-------|--------|------|
| YOLOv8  | 3.01  | 12.93  | 77.4 |
| YOLOv11 | 2.58  | 16.48  | 60.7 |
| RT-DETR | 19.87 | 33.19  | 30.1 |

## 4. 讨论

从模型结构角度来看，不同检测结果的差异与其特征建模方式密切相关。滑坡目标在遥感影像中通常具有分布范围大、形态不规则、内部纹理不均以及边界与周围裸地、阴影区域相互混杂等特点，因此模型不仅需要提取局部纹理和边缘信息，还需要对目标整体形态及其上下文关系进行综合判断。RT-DETR 引入 Transformer 结构后，能够在更大范围内建立特征之间的关联，增强模型对滑坡整体轮廓和空间连续性的表征能力。当滑坡区域内部纹理破碎、局部外观差异较大时，RT-DETR 仍可借助全局上下文信息对目标进行整体识别，从而在大尺度滑坡或复杂背景场景下表现出更好的检测完整性和稳定性。

相比之下，YOLOv8 的 C2f 模块虽然通过特征分支融合增强了梯度流动和特征复用能力，在轻量化和局部特征提取方面具有较好优势，但其核心仍以卷积操作为主，更擅长建模局部邻域内的纹理与边缘信息。对于滑坡这类具有大尺度展布和不规则整体形态的目标，仅依赖局部感受野容易导致模型更关注局部显著纹理，而对目标整体几何结构和长距离依赖关系刻画不足。因此，在滑坡区域与周围裸土、沟谷阴影或道路扰动区具有相似局部纹理时，YOLOv8 更容易出现目标边界不完整、局部漏检或检测框偏移等现象。

综上，RT-DETR 在本研究中的较优表现并不仅仅体现在数值指标提升上，更反映了基于全局关系建模的检测框架在滑坡这类复杂遥感目标识别中的潜在优势；而 YOLOv8 则在保持较高检测效率的同时，受限于卷积特征建模范围，在复杂场景下对滑坡整体轮廓的表达能力相对较弱。

## 5. 结论

本文基于公开滑坡目标检测数据集，选取 YOLOv8、YOLOv11 和 RT-DETR 三种目标检测模型开展

对比实验,并从训练过程、验证指标和可视化检测结果三个方面对模型性能进行了分析。主要结论如下:

(1) 三种模型均能够较好地完成滑坡目标检测任务。训练结果表明, YOLOv8、YOLOv11 和 RT-DETR 的损失函数均随训练轮次增加逐渐下降, Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 等指标持续上升并在后期趋于稳定,说明三种模型均具有较好的收敛性和训练稳定性,能够有效学习滑坡目标特征。

(2) 从定量评价结果来看, RT-DETR 的综合检测性能最好。其 Precision、Recall、mAP@0.5 和 mAP@0.5:0.95 分别达到 0.954、0.950、0.964 和 0.815,均高于 YOLOv8 和 YOLOv11,说明其在滑坡目标识别和边界框定位方面具有更高精度。YOLOv11 的 mAP@0.5 和 mAP@0.5:0.95 略高于 YOLOv8,整体性能略优; YOLOv8 各项指标表现较为均衡,也能够取得较好的检测效果。

(3) 从可视化检测结果来看, RT-DETR 的检测框完整性和稳定性最好,能够较准确地覆盖滑坡区域; YOLOv11 的检测结果整体较稳定,但部分样本的检测框完整性和置信度略低; YOLOv8 在多数样本中能够正确识别滑坡目标,但在个别复杂场景下存在重复检测现象。可视化结果与定量评价结果基本一致。

综上,三种模型均适用于滑坡目标检测任务。其中, RT-DETR 更适合精度要求较高的场景, YOLOv11 整体性能略优于 YOLOv8, YOLOv8 则可作为性能较为均衡的基础模型。本文研究结果可为滑坡目标检测模型选型提供一定参考。

## 参考文献

- [1] 唐亚明, 张茂省, 薛强, 等. 滑坡监测预警国内外研究现状及评述[J]. 地质论评, 2012, 58(3): 533-541.
- [2] 许强, 汤明高, 徐开祥, 等. 滑坡时空演化规律及预警预报研究[J]. 岩石力学与工程学报, 2008(6): 1104-1112.
- [3] 李忠生. 国内外地震滑坡灾害研究综述[J]. 灾害学, 2003(4): 65-71.
- [4] 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.
- [5] 许强, 朱星, 李为乐, 等. “天-空-地”协同滑坡监测技术进展[J]. 测绘学报, 2022, 51(7): 1416-1436.
- [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] 杨军, 兰婉婕. 多目标优化的遥感影像目标检测特征金字塔网络架构搜索方法[J/OL]. 哈尔滨工业大学学报, 1-21. <https://link.cnki.net/urlid/23.1235.T.20260402.1452.002>, 2026-04-23.
- [8] 刘爽, 吕俊良, 秦宇航, 等. 基于 YOLOv8 的 PCB 缺陷检测改进算法[J]. 吉林大学学报(理学版), 2026, 64(2): 344-350.
- [9] 李培辉, 伍红玲, 孙龙, 等. 融合 YOLOv8 与全局注意力机制的滑坡检测模型研究[J]. 自然灾害学报, 2026, 35(1): 81-91.
- [10] Varghese, R. and M., S. (2024) YOLOv8: A Novel Object Detection Algorithm with Enhanced Performance and Robustness. 2024 *International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*, Chennai, 18-19 April 2024, 1-6. <https://doi.org/10.1109/adics58448.2024.10533619>
- [11] Khanam, R. and Hussain, M. (2024) YOLOv11: An Overview of the Key Architectural Enhancements.
- [12] Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., et al. (2024). DETRs Beat YOLOs on Real-Time Object Detection. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 17-21 June 2024, 16965-16974.
- [13] Han, K., Wang, Y., Chen, H., Chen, X., Guo, J., Liu, Z., et al. (2023) A Survey on Vision Transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45, 87-110. <https://doi.org/10.1109/tpami.2022.3152247>
- [14] 涂梨平, 陈美球, 冷鹏. 基于目标检测算法 YOLOv9 的滑坡隐患识别——以永新县为例[J]. 测绘通报, 2025(6): 37-42.
- [15] Liu, Z., Mao, H., Wu, C.Y., Feichtenhofer, C., Darrell, T. and Xie, S. (2022) A ConvNet for the 2020s. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 11966-11976. <https://doi.org/10.1109/cvpr52688.2022.01167>
- [16] 刘子煜, 刘金朝, 孙凯仪, 等. 基于 Stable Diffusion 和 RepViT-YOLOv11 模型的钢轨表面损伤检测方法[J/OL].

铁道建筑, 2026: 1-11. <https://link.cnki.net/urlid/11.2027.u.20260402.0907.002>, 2026-04-23.

- [17] 孔誉霏, 张瑞菊, 庞蕾, 等. PM-YOLO: 多尺度融合的无人机小目标检测算法[J/OL]. 计算机工程与应用, 2026: 1-19. <https://link.cnki.net/urlid/11.2127.tp.20260328.1225.002>, 2026-04-23.
- [18] 郑文韬, 郑红, 孙玉泉, 等. 融合时序特征与运动引导的改进 RT-DETR 飞鸟检测方法[J/OL]. 计算机工程与应用, 2026: 1-12. <https://link.cnki.net/urlid/11.2127.tp.20260401.1545.006>, 2026-04-23.
- [19] 董绍江, 陈智雄, 夏浩然, 等. 基于改进 RT-DETR 的 ROV 机器人水下小目标检测方法[J/OL]. 计算机工程与应用, 2026: 1-13. <https://link.cnki.net/urlid/11.2127.tp.20260328.1536.012>, 2026-04-23.
- [20] 黎作鹏, 张少文, 刘佳祥, 等. 基于 RT-DETR 改进的航拍小目标检测算法[J]. 计算机工程与设计, 2026, 47(3): 879-887.