

DOI:10.13409/j.cnki.jdpme.20230105002

融合YOLOX和ASFF的高原山地灾害检测模型

何明杰, 刘德方, 张 猛, 李高会

(中国电建集团华东勘测设计研究院有限公司, 浙江 杭州 310000)

摘要: YOLOX是全球首个一阶无锚框目标检测模型,超越了YOLO-V(3-5)和SSD等传统锚框模型,极大提高了山地灾害检测识别精度。然而,该模型存在不同尺度之间特征不一致的问题,融合后的特征图质量有待提升。以西藏高原山地灾害重灾区为试验区,在建立了西藏高原山地灾害数据集的基础上,通过融合Adaptively Spatial Feature Fusion(ASFF)注意力机制和骨干网络尺寸调整机制,设计了一个优化的、不同适用性的高原山地灾害检测模型(Plateau mountain disaster detection model, PMDDM)。为验证PMDDM模型的优越性,将其与传统YOLOX模型、不同注意力机制、不同目标检测模型进行了对比分析,并且对不同尺度模型的检测性能和可视化结果也进行了对比分析研究。结果表明:ASFF注意力机制可以有效的解决传统YOLOX模型中存在的不同尺度特征间的特征不一致问题,且对模型检测性能提升明显优于SE、CBAM、ECA、GAM和Coord等注意力机制;PMDDM模型对山地灾害的检测精度优于Faster-RCNN、SSD和YOLO-V3模型,可以满足不同工作场景对硬件配置、检测速度和精度的需求,且模型尺度越大,识别目标的准确率越高。

关键词: 高原山地灾害; 目标检测; 注意力机制; YOLOX; ASFF

中图分类号: TU443 **文献标识码:** A **文章编号:** 1672-2132(2023)06-1215-09

A Plateau Mountain Disaster Detection Model by Integrating YOLOX and ASFF

HE Mingjie, LIU Defang, ZHANG Meng, LI Gaohui
(Power China Huadong Engineering Co., Ltd., Hangzhou 310000, China)

Abstract: YOLOX is the world's earliest first-order anchor-free frame target detection model, which surpasses traditional anchor frame models such as YOLO-V (3-5) and SSD, and greatly improves the accuracy of mountain disaster detection and recognition. However, the model suffers from feature inconsistency between features at different scales, and the quality of the fused feature map needs to be improved. This paper presents the mountain disaster-stricken areas on the Tibetan plateau as the experimental site, based on the basis of the established Tibetan plateau mountain disaster dataset, introduces the Adaptively Spatial Feature Fusion (ASFF) attention mechanism and backbone network size adjustment mechanism to design an optimized system with different applicability. The new plateau mountain disaster detection model (PMDDM) improves the detection accuracy of plateau mountain hazards and enhances the convenience of plateau mountain hazard detection. Meanwhile, the PMDDM model was also compared with traditional YOLOX and other models with different attention

* 收稿日期:2023-01-05;修回日期:2023-03-13

作者简介:何明杰(1973—),男,教授级高工,学士。主要从事水工结构设计和边坡灾害治理研究。E-mail: he_mj@hdec.com

通讯作者:刘德方(1994—),男,博士(后)。主要从事边坡工程防灾减灾方面的研究。E-mail: liudf0303@163.com

mechanisms and different object detection to verify its superiority. The detection performance and visualization results of different scale models are also comparatively analyzed and studied in this paper. The results show that the ASFF attention mechanism can effectively solve the problem of feature inconsistency among different scale features in the traditional YOLOX model; the ASFF attention mechanism improves the model detection performance much better than the attention mechanisms of SE, CBAM, ECA, GAM and Coord; the detection accuracy of the PMDDM model for mountain hazards is better than that of Faster-RCNN, SSD and YOLO-V3 models; the PMDDM model can meet requirements of hardware configuration, detection speed and accuracy for different working scenarios; the larger the scale of PMDDM model, the higher the accuracy rate of identifying targets.

Keywords: plateau mountain hazards; object detection; attention mechanism; YOLOX; ASFF

0 引言

高原山地灾害发生位置的确定是后续减灾救灾工作制定、实施的基础和前提^[1-2]。一般地,在山地灾害发生之后,越早确定灾害的位置,越有助于降低减灾救灾难度、受灾损失和快速恢复生产。然而,受限于高原基础设施分布少、人口密度低、生存环境恶劣等因素,高原山地灾害确定的时间比较晚,救灾难度、危害程度随之增加,如白格滑坡诱发的灾害链^[3-4]。因而,迫切需要一种可以快速确定高原山地灾害发生位置的方法。

目前,确定高原山地灾害位置的方式主要有野外调查^[5]、无人机影像检测^[6]和遥感影像检测^[7]。其中,野外调查是最传统、直接的山地灾害识别方法,在白格滑坡、米林滑坡的减灾救灾工作中发挥了重要作用。但是,该方法速度慢、效率低,而且需要克服高原反应和恶劣的野外生存环境,无法满足对检测速度的实际需求^[8-9]。无人机影像检测是通过无人机机载摄像头获取山地灾害的影像信息,通过影像进行山地灾害的检测。相比于野外调查,在一定程度上提高了检测效率、降低了检测难度,但是无人机在高原也需要面临高原影响,如因空气稀薄导致飞行高度低、续航时间短、信号不容易接收等问题,便不能有效地检测高原山地灾害。遥感影像检测是基于遥感影像,结合图像处理技术来检测山地灾害发生的具体位置。这是一种在无物理接触前提下可以大范围检测地质灾害的方法,已经被广泛应用在山地灾害的识别任务中。

基于图像处理技术的山地灾害检测方法主要包括机器学习和深度学习。其中,常见的机器学习方法有支持向量机^[10]、决策树^[11]等,因其复杂的特征处理过程、容易过拟合、模型泛化能力差等诸多

限制,已经不能满足样本数量大、应用场景复杂的山地灾害检测需求。基于卷积神经网络深度学习模型因其自动学习目标影像深层特征信息的能力、不需要过多人为干扰和大数据处理能力,被广泛地应用到图像处理任务中^[12-13]。目前,基于卷积神经网络的目标检测、语义分割算法被逐步应用到山地灾害的检测任务中。K.Hacıfendioğlu等^[14]制作了印度尼西亚帕卢地区的地震诱发滑坡数据集,对预训练的Faster R-CNN进行训练,实现了对该地区地震诱发滑坡和受损结构的有效检测,验证了遥感影像在滑坡检测中的实际价值。L.Cheng等^[15]基于YOLO-V4,使用群卷积和瓶颈残差模型替换由标准卷积组成的卷积分量和残差模块,通过引入注意力机制模块,提出了轻量级的滑坡检测模型。Z.Y.Su等^[16]使用U-Net对香港大屿山发生的滑坡进行了像素级检测,验证了基于遥感影像检测滑坡的高效性和便捷性。S.P.Ji等^[17]为解决滑坡的特征多样性和复杂背景的干扰,开发了源自人类视觉系统的注意力机制,以促进卷积神经网络从背景中提取滑坡更独特的特征表示。2021年,Z.Ge等^[18]首次提出基于无锚框检测机制的一阶目标检测模型YOLOX。该模型在YOLO基础上,引入了以像元为单位的无锚框机制,融合了像素级分割模型的特征推理能力,进一步提高了模型的检测性能。然而,该模型并没有很好地解决多尺度特征融合模块造成的不同尺度特征不一致问题。并且,高原山地灾害类型多、特征表现复杂、相似性大、背景干扰性强,需要同时满足检测精度和检测速度的实际需求,对检测模型的性能提出了更高的要求。

为此,本文以西藏高原地质灾害重灾区为例,建立了山地灾害遥感影像数据集,在YOLOX基础上,通过插入ASFF注意力机制和调整特征提取模块的宽度和深度,提出了一种多场景适用性的高原

山地灾害快速检测模型(PMDDOM)。通过与YOLOX模型、不同注意力机制、不同目标检测模型对比分析,验证了PMDDOM模型的优越性。通过对不同尺度模型的检测性能和可视化结果的对比分析,确定了模型的不同适用场景。

1 PMDDOM 模型构建

1.1 YOLOX 模型

2021年,Z.Ge等^[18]首次提出了基于无锚框检测机制的一阶目标检测器YOLOX。相比于传统锚框机制检测模型,该模型首次提出了无锚框预测机制,包括无锚框、解耦头、初步筛选、精细化筛选。该模型的检测性能超越了YOLO-V(3-5),为提升山地灾害的检测精度提供了可能。

然而,YOLOX延续了YOLO系列的多尺度特征融合方式,尽管可以提升小目标检测性能,但是不可避免地存在不同尺度特征不一致性问题,影响模型检测性能的进一步提升。因此,本文引入ASFf注意力机制对融合后的特征图进行自适应融合,提升特征图质量。

1.2 ASFf原理及融合机制

ASFf是一种特征自适应融合策略,可以自适应地学习每个尺度特征图的融合空间权重,实现特征在空间上的融合,保证不同尺度特征的一致性。主要操作包括恒等缩放、加权融合系数和自适应融合三部分。恒等缩放包括1/2下采样、1/4下采样和上采样,其中1/2下采样操作为 3×3 conv(stride=2),1/4下采样操作为 3×3 conv(stride=2)和Max Pooling(stride=2)组成,上采样操作为 1×1 conv(stride=1)和interpolation组成。加权融合系数是由网络自适应学习到的,它们在所有通道间是共享的,计算公式为:

$$\alpha_{i,j}^l = \frac{e^{\lambda_{i,j}^l}}{e^{\lambda_{i,j}^l} + e^{\lambda_{i,j}^m} + e^{\lambda_{i,j}^n}} \quad (1)$$

$$\beta_{i,j}^l = \frac{e^{\lambda_{i,j}^m}}{e^{\lambda_{i,j}^l} + e^{\lambda_{i,j}^m} + e^{\lambda_{i,j}^n}} \quad (2)$$

$$\gamma_{i,j}^l = \frac{e^{\lambda_{i,j}^n}}{e^{\lambda_{i,j}^l} + e^{\lambda_{i,j}^m} + e^{\lambda_{i,j}^n}} \quad (3)$$

$$\alpha_{i,j}^l + \beta_{i,j}^l + \gamma_{i,j}^l = 1 \quad (4)$$

自适应融合是由前三个特征图融合得到,融合

后 (i,j) 处的向量是前三个特征图 (i,j) 处向量融合得到的,计算公式为:

$$y_{i,j}^l = \alpha_{i,j}^l \cdot x_{i,j}^{1 \rightarrow l} + \beta_{i,j}^l \cdot x_{i,j}^{2 \rightarrow l} + \gamma_{i,j}^l \cdot x_{i,j}^{3 \rightarrow l} \quad (5)$$

YOLOX与ASFf的融合方式对模型性能影响较大。为有效解决PAFPN模块输出特征图的不一致问题,将ASFf插入PAFPN之后,分别对PAFPN模块输出的3种尺度特征图进行自适应融合,统一不同特征尺度之间的特征信息。

1.3 PMDDOM 模型

图1展示了PMDDOM的模型框架,主要由4部分组成:骨干网络、PAFPN、ASFf和解耦头。其中,骨干网络、PAFPN和解耦头是YOLOX原有的组成模块,ASFf是本文插入的注意力机制模块。

骨干网络主要由Focus、CBS、C3和SPP组成。Focus可以在不丢失影像信息条件下进行采样。CBS由卷积核、Batch Normalization(BN)和SiLu激活函数组成。Bottleneck由两个CBS和跳跃链接组成。C3由CBS、Bottleneck、Concat和跳跃链接组成。它的输入为 $640 \times 640 \times 3$,输出的特征为Stride-8特征图($80 \times 80 \times 256$)、Stride-16特征图($40 \times 40 \times 512$)和Stride-32特征图($20 \times 20 \times 1024$)。

PAFPN用来增强输出特征图中的语义特征和位置信息特征。它的输入为Stride-8特征图、Stride-16特征图和Stride-32特征图,输出为Scale-1*特征图($20 \times 20 \times 1024$)、Scale-2*特征图($40 \times 40 \times 512$)和Scale-3*特征图($80 \times 80 \times 256$)。

ASFf在YOLOX模型的PAFPN后插入,其输入端为Scale-1*特征图、Scale-2*特征图和Scale-3*特征图,输出Scale-1特征图($20 \times 20 \times 1024$)、Scale-2特征图($40 \times 40 \times 512$)和Scale-3特征图($80 \times 80 \times 256$),大小不变。

解耦头将分类任务和定位任务分开,用来提升计算效率。本文共设置3个解耦头,分别对ASFf输出的Scale-1、Scale-2和Scale-3特征图进行目标分类和定位任务。输入Scale-1特征图,通过解耦头可以得到分类结果($20 \times 20 \times 3$)、目标结果($20 \times 20 \times 1$)、位置结果($20 \times 20 \times 4$);输入Scale-2特征图,通过解耦头可以得到分类结果($40 \times 40 \times 3$)、目标结果($40 \times 40 \times 1$)、位置结果($40 \times 40 \times 4$);输入Scale-3特征图,通过解耦头可以得到分类结果($80 \times 80 \times 3$)、目标结果($80 \times 80 \times 1$)、位置结果($80 \times 80 \times 4$)。共计8400个锚框结果。

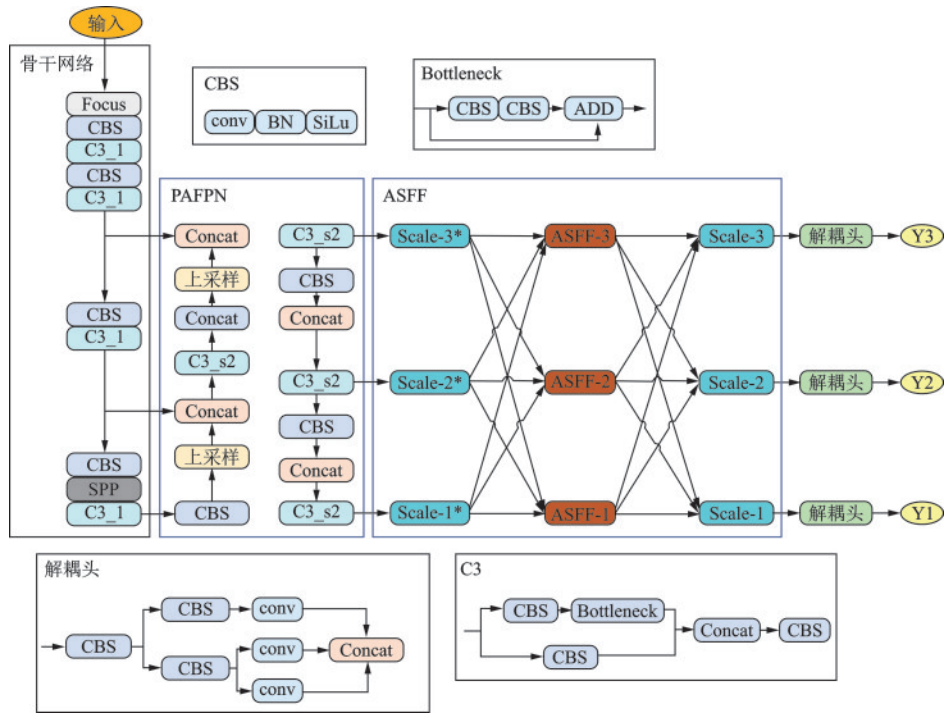


图1 改进YOLOX的模型框架

Fig.1 Improved YOLOX's model framework

1.4 不同适用性模型设计

为将检测模型应用到更广、更多的工作场景,满足对硬件配置、检测精度、实时检测的不同需求,通过调整骨干网络的宽度和深度,开发了不同适用性的高原滑坡检测模型。

表1 不同适用性骨干网络设计

Table 1 Backbone design for different applicability

模型参数	S	M	L
深度	0.33	0.67	1.0
宽度	0.50	0.75	1.0
C3_1	1	2	3
C3_2	3	6	9
C3_3	3	6	9
C3_4	1	2	3

2 青藏高原山地灾害遥感数据集

青藏高原是我国受山地灾害影响和威胁的重灾区,常见的有滑坡、降雨诱发泥石流和冻融诱发泥石流^[19]。该地区的山地灾害有两种破坏模式:直接破坏和次生灾害。其中,直接破坏是指山地灾害对原位置和运动轨迹上的建筑房屋、基础设施等造

成的破坏。次生灾害是指高原山地灾害可能会堵塞河流形成堰塞坝,其溃坝后对下游居民安全、基础设施等造成的破坏。例如白格滑坡对下游梯级水电站的正常运行带来了极大挑战^[1]。主要原因是青藏高原海拔高、地势地形险要、人口密度低等因素,人工徒步的搜寻方式很难快速确定灾害点位置,导致减灾方案制定滞后、后续工作难以及时开展,灾害的危害程度与治理难度急剧加大。因此,迫切需要一种快速、准确地检测高原山地灾害位置的方法,为后续减灾救灾工作提供依据。

根据文献和青藏高原应急救灾的实际需求,本研究选取滑坡、降雨诱发泥石流和冻融诱发泥石流为主要研究对象,分类标准采用O.Hungr等^[20]的滑坡分类系统。灾害数据集主要来源于参考文献、野外调查和目视解译,数据集的获取平台为Google Earth。一共采集到1 161个山地灾害影像,如图2所示,详细信息见表2。获取的山地灾害遥感影像示例如图3~5所示。

3 试验与结果分析

3.1 模型训练设置与评价指标

本文研究所有试验采用相同的软硬件配置环



图2 青藏高原山地灾害数据集分布示意

Fig.2 Distribution of mountain hazard datasets in the Tibetan plateau

表2 青藏高原山地灾害数据集

Table 2 Tibetan Plateau Mountain Hazards Dataset

类型	滑坡	降雨诱发泥石流	冻融诱发泥石流	合计
训练集	372	200	200	772
验证集	63	33	33	129
测试集	126	67	67	260
合计	561	300	300	1 161




图3 滑坡遥感影像示例

Fig.3 Example of remote sensing image of landslide




图4 降雨诱发泥石流遥感影像示例

Fig.4 Example of remote sensing images of rainfall-induced debris




图5 冻融诱发泥石流遥感影像示例

Fig.5 Example of remote sensing images of freeze-thaw induced debris

境,其中硬件主要 Intel Xeon® Gold 5118 CPU 和 GeForce RTX 2080 Ti 11G GPU,操作环境为 Ubuntu 18.04, CUDA-10.1.105, Python-3.7.11, torch-1.9.0 等。训练时的超参数设置:warmup_ep-

ochs 为 5, warmup_lr 为 0, basic_lr_per_img 为 0.01/64, no_aug_epochs 为 15, min_lr_ratio 为 0.05, ema 为 True, weight_decay 为 5e-4, momentum 为 0.9, Max_epoch 为 300。

采用的评价指标为平均正确率(Average Precision, AP)、均值平均正确率(mean Average Precision, mAP)和 Frames Per Second(FPS)。其中,AP 的计算公式为:

$$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) P_{\text{inter}}(r_i + 1) \quad (6)$$

式中, $P(r)$ 表示在 $[r_i, r_{i+1}]$ 范围内样本中的最大值; r_i 为 $[0, 0.1, 0.2, \dots, 1.0]$ 范围内。

mAP 是每一类地质灾害 AP 总和的平均,计算公式为:

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i \quad (7)$$

式中, k 为目标检测类别数量,本文为 3。

FPS 为检测模型每秒可以检测的图像数量,当 FPS 大于 30 张/s 时,模型达到实时检测的标准。

3.2 PMDDOM 与 YOLOX 对比

为验证选用 ASFF 注意力机制对 YOLOX 检测性能提升的有效性,选用高原滑坡数据集分别对 PMDDOM 和 YOLOX 的 S、M、L 尺度模型进行了训练和测试,结果见表 3。可以发现:相较于 YOLOX,在 S 尺度模型,PMDDOM 的 $AP_{\text{滑坡}}$ 、 $AP_{\text{降雨诱发泥石流}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 、mAP 分别提升了 0.023、0.013、0.018、0.018,在 M 尺度模型,PMDDOM 的 $AP_{\text{滑坡}}$ 、 $AP_{\text{降雨诱发泥石流}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 、mAP 分别提升了 0.017、0.040、0.006,在 L 尺度模型,PMDDOM 的 $AP_{\text{滑坡}}$ 、 $AP_{\text{降雨诱发泥石流}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 分别提升了 0.015、0.032、0.017。可见,PMDDOM 在 S、M、L 三种尺度的检测性能优于 YOLOX 模型,选用 ASFF 注意力机制可以明显提升 PMDDOM 的高原山地灾害检测精度,解决了不同尺度特征不一致问题。

3.3 不同注意力机制对比

为验证选用 ASFF 注意力机制的合理性,选用 SE^[21]、CBAM^[22]、ECA^[23]、GAM^[24]、Coord^[25] 5 种注意力机制为参照组,分别插入 YOLOX-S、YOLOX-M 和 YOLOX-L 并进行训练和测试,计算得到的结果见表 4~6。

表 4 是不同注意力机制在 S 尺度模型上的计算结果,可以发现:从单一类别目标检测精度来看,

ASFF 在 S 尺度模型上的 $AP_{\text{滑坡}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 是 0.849、0.784, 优于 SE、CBAM、ECA、GAM、Coord 注意力机制。尽管 CBAM 的 $AP_{\text{降雨诱发泥石流}}$ 略优于其它注意力机制, 但是在滑坡和冻融诱发泥石流上的表现较 ASFF 差很多。从 mAP 来看, ASFF 在 S 尺度模型上的 AP 优于 SE、CBAM、ECA、GAM、Coord 注意力机制, 表明 ASFF 对 S 尺度模型检测性能的提升优于参照组注意力机制。

表 3 PMDDOM 和 YOLOX 实验结果对比

Table 3 Comparison results of PMDDOM and YOLOX

模型 尺度	模型	$AP_{\text{滑坡}}$	$AP_{\text{降雨诱发泥石流}}$	$AP_{\text{冻融诱发泥石流}}$	mAP
S	PMDDOM	0.849	0.746	0.784	0.793
	YOLOX	0.826	0.733	0.766	0.775
M	PMDDOM	0.849	0.783	0.801	0.811
	YOLOX	0.832	0.743	0.795	0.790
L	PMDDOM	0.840	0.815	0.801	0.819
	YOLOX	0.825	0.783	0.784	0.797

表 4 不同注意力机制的 S 尺度模型检测结果

Table 4 Detection results of S-scale models with different attention mechanisms

注意力机制	$AP_{\text{滑坡}}$	$AP_{\text{降雨诱发泥石流}}$	$AP_{\text{冻融诱发泥石流}}$	mAP
SE	0.844	0.736	0.769	0.783
CBAM	0.821	0.757	0.738	0.772
ECA	0.840	0.727	0.743	0.770
GAM	0.828	0.722	0.777	0.776
Coord	0.815	0.753	0.751	0.773
ASFF	0.849	0.746	0.784	0.793

表 5 是不同注意力机制在 M 尺度模型上的计算结果, 可以发现: 从单一类别目标检测精度来看, ASFF 在 M 尺度模型上的 $AP_{\text{滑坡}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 、 $AP_{\text{降雨诱发泥石流}}$ 是 0.849、0.783、0.801, 优于 5 种参照组注意力机制。从 mAP 来看, ASFF 在 M 尺度模型上的 AP 优于 5 种参照组注意力机制, 表明 ASFF 对 M 尺度模型检测性能的提升优于参照组注意力机制。

表 6 是不同注意力机制在 L 尺度模型上的计算结果, 可以发现: 从单一类别目标检测精度来看, ASFF 在 L 尺度模型上的 $AP_{\text{降雨诱发泥石流}}$ 和 $AP_{\text{冻融诱发泥石流}}$ 分别是 0.815 和 0.801, 明显优于 5 种参照组注意力机制。尽管 CBAM、ECA、Coord 在 L 尺度模型上的 $AP_{\text{滑坡}}$ 略优于 ASFF, 但是对降雨诱发泥石流和冻融诱发泥石流的识别精度较低。SE 在

L 尺度模型上的 $AP_{\text{滑坡}}$ 值最高, 但是在降雨诱发泥石流类别的检测效果较 ASFF 差 0.57。主要原因为 5 种参照组注意力机制只对滑坡目标比较敏感, 而对降雨诱发泥石流的识别能力差。从 mAP 来看, ASFF 在 L 尺度模型上的 mAP 值优于 5 种参照组注意力机制, 表明 ASFF 对 L 尺度模型检测性能的提升优于参照组注意力机制。

表 5 不同注意力机制的 M 尺度模型检测结果

Table 5 Detection results of M-scale models with different attention mechanisms

注意力机制	$AP_{\text{滑坡}}$	$AP_{\text{降雨诱发泥石流}}$	$AP_{\text{冻融诱发泥石流}}$	mAP
SE	0.821	0.763	0.785	0.790
CBAM	0.845	0.751	0.797	0.797
ECA	0.834	0.727	0.806	0.789
GAM	0.843	0.762	0.760	0.788
Coord	0.824	0.780	0.786	0.797
ASFF	0.849	0.783	0.801	0.811

表 6 不同注意力机制的 L 尺度模型检测结果

Table 6 Detection results of L-scale models with different attention mechanisms

注意力机制	$AP_{\text{滑坡}}$	$AP_{\text{降雨诱发泥石流}}$	$AP_{\text{冻融诱发泥石流}}$	mAP
SE	0.854	0.758	0.794	0.802
CBAM	0.848	0.800	0.793	0.814
ECA	0.846	0.773	0.788	0.802
GAM	0.837	0.769	0.779	0.795
Coord	0.842	0.758	0.795	0.798
ASFF	0.840	0.815	0.801	0.819

综上所述, 选用 ASFF 注意力机制对模型检测性能的提升优于 SE、CBAM、ECA、GAM、Coord 注意力机制, 表明 ASFF 对滑坡、降雨诱发泥石流和冻融诱发泥石流特征的整体敏感性强, 识别能力高, 这也验证了选用 ASFF 相较于选用参照组注意力机制的合理性。

3.4 不同目标检测模型对比

为验证 PMDDOM 模型检测性能的优越性, 选用 Faster-RCNN、SSD、YOLO-V3 作为参照组进行对比测试分析, 结果见表 7。可以发现, PMDDOM 系列模型在 $AP_{\text{滑坡}}$ 、 $AP_{\text{降雨诱发泥石流}}$ 、 $AP_{\text{冻融诱发泥石流}}$ 和 mAP 的检测值明显优于参照组, 验证了 PMDDOM 的优越性。

表7 不同检测模型检测结果

检测模型	AP _{滑坡}	AP _{降雨诱发泥石流}	AP _{冻融诱发泥石流}	mAP
Faster-RCNN	0.740	0.545	0.535	0.518
SSD	0.699	0.451	0.605	0.585
YOLO-V3	0.746	0.682	0.707	0.712
PMDDOM-S	0.849	0.746	0.784	0.793
PMDDOM-M	0.849	0.783	0.801	0.811
PMDDOM-L	0.840	0.815	0.801	0.819

3.5 PMDDOM 适用性分析

本文一共设计了S、M、L三种不同尺度的山地灾害检测模型,选用的评价指标为AP、mAP、FPS、模型大小,结果见表8。可以发现:PMDDOM-S模型的检测精度低,检测速度快,模型最小,适用于检测速度要求高、硬件配置低、检测精度要求低的应用场景;PMDDOM-L模型的检测精度高,检测速度低、模型最大,适用于检测精度要求高、硬件配置高、检测速度要求低的场景;PMDDOM-M模型的检测精度、检测速度、FPS、模型大小居中,适用于对单一检测要求不高、硬件配置居中的工作环境。需要强调的是,所有检测模型的FPS 30张/s,全部满足实时检测的需求。

表8 不同适用性模型检测结果

检测模型	AP _{滑坡}	AP _{降雨诱发泥石流}	AP _{冻融诱发泥石流}	mAP	FPS	大小
PMDDOM-S	0.849	0.746	0.784	0.793	125	71.8
PMDDOM-M	0.849	0.783	0.801	0.811	83	202.7
PMDDOM-L	0.840	0.815	0.801	0.819	52	433.9

3.6 不同尺度PMDDOM 可视化分析

图6是PMDDOM模型的滑坡检测结果示例,黄色矩形框表示滑坡标定区域。可以发现,对于同一个滑坡目标,PMDDOM-L的识别准确率为81.8%、PMDDOM-M的识别准确率为79.1%、PMDDOM-S的识别准确率为76.4%。这表明模型的尺度越大,对滑坡的识别准确率越高。




图6 滑坡检测结果可视化示例

Fig.6 Example of landslide detection result visualization

图7是PMDDOM模型的降雨诱发泥石流检测结果示例,蓝色矩形框表示降雨诱发泥石流标定区域。可以发现,对于同一个降雨诱发泥石流目标,PMDDOM-L的识别准确率为72.4%、PMDDOM-M的识别准确率为53.2%、PMDDOM-S的识别准确率为33.1%。这表明模型的尺度越大,对降雨诱发泥石流的识别准确率越高。

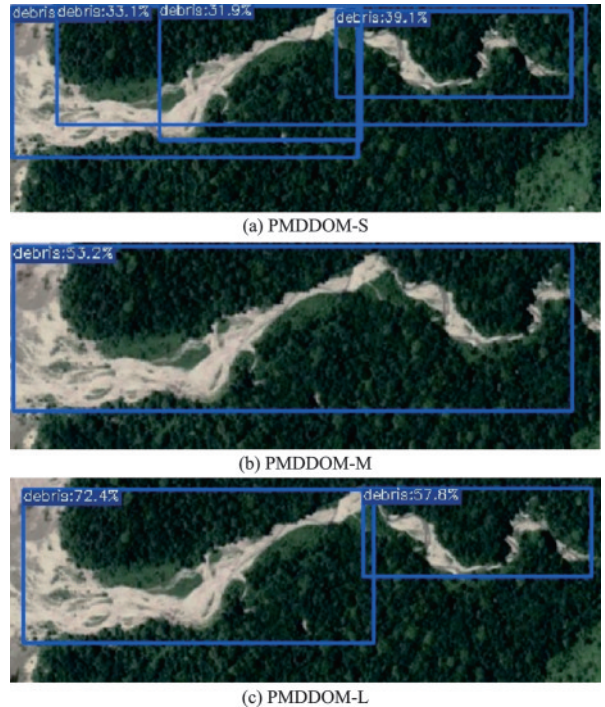


图7 降雨诱发泥石流检测结果可视化示例

Fig.7 Example of visualization of rainfall-induced debris detection results

图8是PMDDOM-L模型的冻融诱发泥石流检测结果示例,浅蓝色矩形框表示冻融诱发泥石流标定区域。可以发现,对于同一个冻融诱发泥石流目标,PMDDOM-L的识别准确率为81.2%、PMDDOM-M的识别准确率为80.4%、

PMDDOM-S 的识别准确率为 77.2%。这表明模型的尺度越大,对冻融诱发泥石流的识别准确率越高。图 8(c)右下角被标定为冻融诱发泥石流,说明 PMDDOM-L 可以根据冻融诱发泥石流的局部信息识别到目标。

总的来说,PMDDOM 的模型尺度越大,识别目标的准确率越高,并且 PMDDOM-L 可以根据目标的局部信息识别目标。




图 8 冻融诱发泥石流检测结果可视化示例

Fig.8 Example of visualization of freeze-thaw induced debris flow detection results

4 结 论

针对 YOLOX 多尺度特征融合模块的特征不一致问题,通过引入 ASFF 注意力机制和调整特征提取模块的宽度和深度,提出了不同适用性的高原山地灾害检测模型 PMDDOM。以青藏高原重灾区为例,选取滑坡、降雨诱发泥石流和冻融诱发泥石流为检测对象,对模型进行了训练和测试。为验证 PMDDOM 的优越性,与 YOLOX 模型、不同注意力机制、不同目标检测模型进行了对比分析。为验证模型的适用性,对不同尺度模型的检测性能和可视化结果进行了对比分析。结果表明:

(1)ASFF 可以有效解决 YOLOX 模型中存在的不同尺度特征间的特征不一致问题,提升高原山地灾害的检测精度。选用 ASFF 注意力机制对模型检测性能的提升优于 SE、CBAM、ECA、GAM、Coord 注意力机制;PMDDOM 高原山地灾害检测模型在滑坡、降雨诱发泥石流、冻融诱发泥石流的检测性能优于当前经典的目标检测模型 Faster-RCNN、SSD、YOLO-V3。

(2)不同尺度 PMDDOM 的适用场景不同。PMDDOM-S 适用于检测速度要求高、硬件配置低、检测精度要求低的应用场景,PMDDOM-L 适用于检测精度要求高、硬件配置高、检测速度要求低的应用场景,PMDDOM-M 适用于对单一检测要求不高、硬件配置居中的工作环境。

(3)PMDDOM 的模型尺度越大,识别目标的准确率越高。同时,PMDDOM-L 可以根据目标的局部信息推断出目标的具体位置。

参考文献:

- [1] Zhang L M, Xiao T, He J, et al. Erosion-based analysis of breaching of Baige landslide dams on the Jinsha River, China, in 2018[J]. Landslides, 2019, 16(10): 1965-1979.
- [2] Jia H C, Chen F, Pan D H. Disaster chain analysis of avalanche and landslide and the river blocking dam of the Yarlung Zangbo River in Milin County of Tibet on 17 and 29 October 2018[J]. International Journal of Environmental Research and Public Health, 2019, 16(23):4707.
- [3] Liu G, Li J. Research on the effect of tree barriers on rockfall using a three-dimensional discontinuous deformation analysis method [J]. International Journal of Computational Methods, 2020, 17(8): 1950046.
- [4] 李睿祺, 胡桂胜, 陈宁生, 等. 川藏铁路沟谷型泥石流形成运动特征与工程危害研究[J]. 防灾减灾工程学报, 2021, 41(3): 432-440,462.
Li R Q, Hu G S, Chen N S, et al. Study on formation and motion characteristics and engineering hazards of gully type debris flow in Sichuan Tibet Railway [J]. Journal of Disaster Prevention and Mitigation Engineering, 2021, 41(3): 432-440,462. (in Chinese)
- [5] 张庆海. 1/5 万县(市)地质灾害调查野外工作方法概述[J]. 科技资讯, 2015, 13(22): 220-221.
Zhang Q H. 1/5 Overview of fieldwork methods for geohazard surveys in 10,000 counties (cities)[J]. Science & Technology Information, 2015, 13(22): 220-

221. (in Chinese)
- [6] 雷添杰, 李长春, 何孝莹. 无人机航空遥感系统在灾害应急救援中的应用[J]. 自然灾害学报, 2011, 20(1): 178-183.
Lei T J, Li C C, He X Y. Application of aerial remote sensing of pilotless aircraft to disaster emergency rescue [J]. Journal of Natural Disasters, 2011, 20(1): 178-183. (in Chinese)
- [7] 杨婷婷. 基于遥感综合分析的灾害地质研究[D]. 北京: 中国地质大学(北京), 2020.
Yang T T. Research on disaster geology based on comprehensive analysis of remote sensing[D]. Beijing: China University of Geosciences (Beijing), 2020. (in Chinese)
- [8] 叶唐进, 谢强, 王鹰. 国道G318巴塘至拉萨段碎屑斜坡灾害与稳定性分析[J]. 安全与环境学报, 2018, 18(5): 1917-1922.
Ye T J, Xie Q, Wang Y. Slope disaster and stability analysis of the G318 Highway in the section from Batang to Lhasa [J]. Journal of Safety and Environment, 2018, 18(5): 1917-1922. (in Chinese)
- [9] 叶唐进, 曹景轩, 张宇, 等. 基于三维地形仿真的高原落石运动特征分析[J]. 高原科学研究, 2022, 6(2): 60-68.
Ye T J, Cao J X, Zhang Y, et al. Analysis of rockfalls movement characteristics on the Tibetan Plateau based on 3D terrain simulation[J]. Plateau Science Research, 2022, 6(2): 60-68. (in Chinese)
- [10] Okwuashi O A, Ndehedehe C E N. Deep support vector machine for hyperspectral image classification [J]. Pattern Recognition, 2023, DOI: 10.1016/j.patcog.2020.107298.
- [11] Song Y Y, Ying L. Decision tree methods: applications for classification and prediction[J]. Shanghai Archives of Psychiatry, 2015, 27(2): 130.
- [12] 刘汉龙, 马彦彬, 仇文岗. 大数据技术在地质灾害防治中的应用综述[J]. 防灾减灾工程学报, 2021, 41(4): 710-722.
Liu H L, Ma Y B, Zhang W G. Application of big data techniques in geological disaster analysis and prevention: a systematic review [J]. Journal of Disaster Prevention and Mitigation Engineering, 2021, 41(4): 710-722. (in Chinese)
- [13] 裴振伟, 年廷凯, 吴昊, 等. 滑坡地质灾害应急处置技术研究进展[J]. 防灾减灾工程学报, 2021, 41(6): 1382-1394.
Pei Z W, Nian T K, Wu H, et al. Research progress on emergency treatment techniques for landslide geological hazards [J]. Journal of Disaster Prevention and Mitigation Engineering, 2021, 41(6): 1382-1394. (in Chinese)
- [14] Hacıfendioglu K, Başağa H B, Demir G. Automatic detection of earthquake-induced ground failure effects through Faster R-CNN deep learning-based object detection using satellite images [J]. Natural Hazards, 2021, 105(1): 383-403.
- [15] Cheng L, Li J, Duan P, et al. A small attentional YOLO model for landslide detection from satellite remote sensing images[J]. Landslides, 2021, 18(8): 1-15.
- [16] Su Z Y, Chow J K, Tan P S, et al. Deep convolutional neural network-based pixel-wise landslide inventory mapping[J]. Landslides, 2021, 18(4): 1421-1443.
- [17] Ji S P, Yu D W, Shen C Y, et al. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks[J]. Landslides, 2020, 17(6): 1337-1352.
- [18] Ge Z, Liu S, Wang F, et al. YOLOX: exceeding YOLO series in 2021 [J]. ArXiv E-Prints, 2021, DOI: 10.48550/arXiv.2017.08430.
- [19] 崔鹏, 苏凤环, 邹强, 等. 青藏高原山地灾害与气象灾害风险评估与减灾对策[J]. 科学通报, 2015, 60: 3067-3077.
Cui P, Su F H, Zou Q, et al. Risk assessment and disaster reduction strategies for mountainous and meteorological hazards in Tibetan Plateau [J]. Chinese Science Bulletin, 2015, 60: 3067-3077. (in Chinese)
- [20] Hungro O, Leroueil S, Picarelli L. The Varnes classification of landslide types, an update [J]. Landslides, 2014, 11(2): 167-194.
- [21] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2018: 7132-7141.
- [22] Woo S, Park J, Lee J-Y, et al. Cbam: Convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision. Seattle, WA, USA: IEEE, 2018: 3-19.
- [23] Wang Q, Wu B, Zhu P, et al. Supplementary material for 'ECA-Net: Efficient channel attention for deep convolutional neural networks [C]//Proceedings of the Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 13-19.
- [24] Liu Y, Shao Z, Hoffmann N. Global attention mechanism: retain information to enhance channel-spatial interactions [J]. ArXiv E-Prints, 2021, DOI: 10.48550/arXiv.2112.05561.
- [25] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design [C]// Proceedings of the Proceedings of the IEEE/CVF conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2021: 13713-13722.

(本文编辑: 赵霞)