

无人机高分遥感图像检测震灾中损坏建筑物

王海峰^{1,2}, 周成江^{1,2}, 陈雪峰³, 杨扬^{1,2,4}

1. 云南师范大学 信息学院, 昆明 650500;

2. 云南师范大学 人工智能和模式识别实验室, 昆明 650500;

3. 云南省救灾物资储备中心, 昆明 650300;

4. 云南师范大学 物理与电子信息学院, 昆明 650500

摘要: 中国云南省自然灾害频发, 给人们造成了巨大生命财产损失。为此本文基于无人机高分遥感图像和深度学习的目标检测技术快速定位自然灾害中损坏建筑物的位置, 为救灾救援提供助力。然而, 目前损坏建筑物检测领域仍存在一些挑战: 如目前公开的震灾损坏建筑物的高分辨率数据较少或费用昂贵; 待检测损坏建筑物与背景及其他目标特征差异小而错检的问题。针对以上问题, 本文构建了基于无人机遥感图像的大规模高分辨率的震灾损坏建筑物数据集, 其主要在云南省大理白族自治州漾濞彝族自治县灾区收集 4598 张遥感图像, 并对目标建筑物进行了多种形式标注; 在检测算法上, 本文提出了震灾损坏建筑物实时检测模型, 其中包含目标特征对齐模块, 特征差异计算模块和目标边界约束的位置框检测模块。本文提出的模型在震灾建筑物检测数据集上达到了 86% 的精度, 同时也在不同地点的实际场景下进行了验证并得到较好的效果。

关键词: 深度学习, 高分遥感图像, 目标检测, 变化检测, 地震灾害

中图分类号: P2

引用格式: 王海峰, 周成江, 陈雪峰, 杨扬. 2024. 无人机高分遥感图像检测震灾中损坏建筑物. 遥感学报, 28(4): 911-925

Wang H F, Zhou C J, Chen X F and Yang Y. 2024. Detection of earthquake-damaged buildings via UAV high-resolution remote sensing images. National Remote Sensing Bulletin, 28(4): 911-925 [DOI: 10.11834/jrs.20221569]

1 引言

中国云南省地震、泥石流等自然灾害频繁发生。根据中国地质资料馆的调查数据显示, 云南省陆良县, 罗平县, 师宗县仅 3 地共有地质灾害隐患 279 个, 包括滑坡 217 个、崩塌 32 个、泥石流 6 条、地面塌陷 24 个。自然灾害发生时若不能及时救援, 造成生命及财产损失将不可估计。因此需要快速识别损坏房屋等其他建筑物来定位受灾区域, 进而制定精准的救援计划。在西南高原地区, 由于其面积广阔、地形复杂和树木遮挡等因素, 对于损坏建筑物检测任务提出了苛刻的要求。基于遥感图像的大尺度范围灾害检测是一个热门的研究方向, 深度学习技术在该领域发挥着重要的作用。其突破点在于大尺度下的小目标检测技术 (Nie 等, 2018)、模型实时检测技术 (Dong 等, 2019)、

弱差异特征的目标检测技术 (Wang 等, 2021)。

目前研究对自然灾害检测和震灾建筑物识别做出了不同的贡献。但对于高海拔多山林的云南高原灾区检测仍然面临很大的挑战: (1) 遥感图像中待检测目标分辨率低。(2) 在大尺度图像中房屋是否损坏难以辨别, 如倒塌的房屋, 目标相对于背景和其他物体的特征差异不明显, 模型难以识别。(3) 高原地区多山多林的复杂环境, 如待检测目标被树木半遮挡。针对这些问题本文提出基于无人机遥感图像的大规模高分辨的震灾建筑物数据集, 同时提出了基于深度学习的震灾损坏建筑物实时检测模型 EDBRDM (Earthquake Damage Buildings Real-time Detection Model), 首先目标特征对齐模块 OFAM (Object Feature Alignment Module) 矫正震灾前后数据中目标特征非对齐问题, 特征差异计算模块 FDCM (Feature Difference

收稿日期: 2021-09-06; 预印本: 2022-03-22

基金项目: 国家自然科学基金(编号: 41971392); 云南万人计划; 云南师范大学研究生科研创新基金(编号: ysydys2020148)

第一作者简介: 王海峰, 研究方向为目标检测、深度学习的理论和应用。E-mail: whf200608@163.com

通信作者简介: 杨扬, 研究方向为人工智能和模式识别。E-mail: yyang_ynu@163.com

Calculation Module) 再进行特征差异计算来增强损坏建筑物的目标特征。最后利用基于目标边界约束的位置框检测模块 OBCPB (Object Boundary Constraint based-Position Box detection module) 进行精确检测损坏建筑物目标。

2 相关工作

本节系统地调查了灾后建筑物损毁评估方法及相关应用。首先调查了使用较为廉价方便的无人机高分遥感技术在救灾和数据采集方面的研究及应用; 然后调查了目前流行的建筑物损毁检测评估方法; 最后调查研究了最新的深度学习技术在高分遥感领域的应用, 以及细节特征提取、小目标检测等方面的研究分析。

无人机在灾区数据采集和辅助救援方面已成为较重要的工具。Sarosa 等 (2021) 使用基于无人机遥感技术的实时检测模型 YOLO 对灾区中受伤人员检测, 为灾区救援提供搜救信息。Mishra 等 (2020) 利用无人机对偏远灾区快速扫描以加快搜救 (SAR) 的速度来挽救更多的生命。并且提出一种用于 SAR 人体动作检测的图像数据集。Zhu 等 (2021) 通过航拍视频来分析自然灾害, 并提出了对边界框进行置信度得分校准的无监督得分细化网络。Pulvirenti 等 (2020) 提出了一种基于聚类 and 阈值的自动检测多时相频谱指数变化的方法, 并在自然灾害损害评估中进行应用。Yamazaki 等 (2020) 设计了一种使用无人飞行器的人类搜索系统。将语音识别和人体检测相结合以弥补它们各自的缺点。Weiss 等 (2020) 这些研究对灾区救援提供了理论和有效的方法。

目前建筑物损毁检测评估主要基于卫星或航空遥感影像, 在大尺度上分析具有一定的优势。S. Fujita 和 Hatayama (2023) 研究开发了屋顶受损建筑物的估计系统, 基于航空照图像使用深度学习技术获得地震损坏的概况。为了快速估计, 该系统采用修剪算法, 并使用 GIS 上建筑物多边形的位置信息自动生成屋顶图像数据。Gonzalez-Drigo 等 (2019) 收集了 2011 年 5 月 11 日洛尔卡地震 (西班牙穆尔西亚) 中严重受损建筑物数据。通过经验和数值方法分析了建筑物的损坏程度。Li 等 (2021) 以 2008 年 5 月 12 日发生在中国汶川的地震为例, 提出了一种基于同震变形的建筑物破坏程度评估方法。收集了 51 个建筑样本, 并对地震破

坏调查数据进行了分析。Zhang 等 (2017) 基于卫星遥感图像给建筑物标记, 为训练集标签和测试集标签设计了单独策略, 并训练了带有分类标签的弱监督检测模型以及带有少量像素级标签的半监督方法。Aamir 等 (2019) 提出了一种从低对比度卫星图像中检测建筑物的方法。先基于离散小波变换 (DWT) 的奇异值分解 (SVD) 优化图像对比度来表示目标信息, 再检测建筑物的完整轮廓。

深度学习技术基于高分遥感图像检测建筑物的调查研究。Wang 等 (2019) 基于深度神经网络条件随机场分割高分辨率遥感图像建筑物。以深度残差神经网络为基础, 构建 Encoder-Decoder 的深度学习架构, 自动提取建筑物的特征, 学习建立高维强非线性分割模型。Shen 等 (2021) 提出了一种用于建筑损坏评估的两阶段卷积神经网络 BDANet, 通过交叉注意力模块来探索灾前后卫星图像之间的相关性来检测损坏的建筑物。Zheng 等 (2021) 提出了一种基于深度目标的语义变化检测框架 ChangeOS。采用深度目标定位网络来准确定位建筑目标, 并将目标定位和损坏分类网络集成到语义变化检测网络中, 用于建筑物损坏检测。Kampffmeyer 等 (2016) 提出一种深度卷积神经网络用于遥感图像中的土地覆盖制图。针对土地覆盖制图任务中类不平衡的问题, 提出了一种新颖的方法来实现整体高精度, 同时仍然对小物体识别实现良好的精度。Ren 等 (2018) 研究了针对光学遥感图像中的小物体检测任务。不仅通过设置适当的锚点, 而且还采用自顶向下和跳跃连接架构来利用高分辨率的单个高级特征图, 进而提高小物体检测精度。Zheng 等 (2020) 提出了一种前景感知关系网络 FarSeg, 通过学习前景—场景关联的上下文来增强对前景特征的区分。同时提出了一种前景感知优化以实现增强检测目标特征。

3 数据描述

3.1 数据来源

本文构建了基于无人机遥感的震灾损坏建筑物数据集 UEDB (UAV remote sensing-based earthquake-damaged buildings database) 是由中国地震局在云南省大理白族自治州漾濞彝族自治县地震灾区收集的数据, 如图 1 所示, 由云南师范大

学信息学院人工智能和模式识别实验团队加工处理。本研究还收集了震灾前的遥感数据，并在大理和丽江等地区使用无人机采集大量的视频数据。该数据是经过人工严格地数据筛选并进行规范标注，并且是目前公开震灾损害建筑遥感图像中最高分辨率数据集。UEDB的优势特征：（1）数据收集及时，对研究本次震灾中建筑物损坏分布情况具有实效性。（2）震灾前后数据采集间隔短，能够在震灾短时间尺度上分析其特性，避免其他因素的影响。（3）高分辨率图像数据，图像信息内容可表达建筑物的细节特征。



图1 云南省震灾损坏建筑物的数据
Fig. 1 Data of earthquake-damaged buildings in Yunnan

3.2 数据标注


本文提出的数据集包含 4598 张图像，其中 2566 张大尺度高分辨率的灾后数据，1032 张区域非对齐的灾前数据和 1000 张手工矫正区域对齐的灾前数据，如图 2 所示。该数据集有 3 种格式的标注：目标位置框标注，目标边界多边形框标注，目标分割标注。建筑物目标位置框标注 76016 个实例，如图 3（a）所示，其中 69477 个无损建筑物标注实例，6320 个轻度损坏建筑物标注实例，219 个重度损坏建筑物标注实例。建筑物目标边界多边形框标注 76016 个实例如图 3（b），分割标注 76016 个实例如图 3（c）。标注建筑物目标尺度大小为 6×5—130×125 像素。为了更好利用震灾前后数据的对应特征，对震灾前后数据进行了人工矫正对齐，共有 1000 对图像数据，其对齐误差范围 0—10 像素。未对齐的图像位置差在 100—200 像素。震灾后数

据尺寸大小为 1000×1000—2560×2560 像素，震灾前数据尺寸在 450×450—2560×2560 像素之间，灾后数据的空间分辨率 0.03—1 m。



□ 对齐区域

图2 震灾前后数据手工矫正
Fig. 2 Manually corrected data of earthquake-damaged buildings



(a) 建筑物位置框标注
(a) Building location box labels



(b) 建筑物边界多边形框标注
(b) Building bounding polygon box labels



(c) 建筑物分割标注
(c) Building bounding mask labels



图3 建筑物多种类型标签
Fig. 3 Buildings multiple-types labels

3.3 数据集对比

现有的公开震灾建筑物检测数据集有 xView2 XDB (Gupta等, 2019)、WHU Building (Ji等, 2019) 数据集。xView2 XDB 包含 15 中自然灾害, 其地震数据包含 200 对震灾前后数据如图 4 (a), 数据是距离地面采样 0.3 m 的 WorldView-3 卫星收集, 并标注了建筑物损坏类别和边界框。WHU Building 数据集是由武汉大学遥感信息工程学院季顺平团队收集如图 4 (b), 其中地震数据集共有 875 对震灾前后数据, 其时间分别为 2012 年和 2016 年, 此数据适合震灾区域的长时间尺度的研究。本文提出的数据集 UEDB (图 5) 与其他数据集对比, 具有明显的优势。



图 4 现有的地震损坏建筑物检测数据集

Fig. 4 Existing datasets of earthquake-damaged buildings



图 5 UEDB 震灾后建筑物展示

Fig. 5 Display of buildings after the earthquake in UEDB

4 方法

针对要解决的问题, 本文提出了震灾建筑物损坏实时检测模型 EDBRDM, 其整体流程如图 6

所示。该模型针对数据中的震灾前后图像非对齐, 分辨率不一致和损坏建筑物目标特征弱的问题。目的是要在解决这些问题的基础上, 实现损坏建筑物目标位置的检测。EDBRDM 包含 3 个模块: 目标特征对齐模块, 特征差异计算模块, 目标边界约束的位置框检测模块。利用震灾前后数据的特征差异及建筑物边界信息来增强模型的检测能力。

4.1 目标特征对齐模块

震灾前后遥感数据由于收集过程中无人机轨迹误差造成对应图像的偏移。在进行震灾前后数据特征差异计算前, 需要矫正目标特征对应位置, 因此本文设计了目标特征对齐模块 OFAM, 如图 7 所示。数据集中有手工粗矫正数据和未矫正数据, 因此 OFAM 有两种对齐方式: 粗对齐和微调对齐。震灾前手工矫正数据表示为 $X'_{w,h}$, 震灾后数据表示为 $Y_{w,h}$, 并且 $w_y \ll w_x$, $h_y \ll h_x$ 。在数据处理时有 3 种不同情况: $\{X'_{w,h}, X_{w,h}, Y_{w,h}\}$, $\{X'_{w,h}, Y_{w,h}\}$, $\{X_{w,h}, Y_{w,h}\}$, 当 $\{X'_{w,h}, X_{w,h}, Y_{w,h}\}$ 时, $X'_{w,h} \xrightarrow{T(\Delta w, \Delta h, \Delta s)} X'_{w',h'}$, $X'_{w',h'} \in X_{w,h}$ 。公式中表达中的主要问题是 Δw , Δh , Δs 参数的预测, 本文使用纠缠的特征信息来预测 3 个参数。震灾前后的数据使用权重共享的特征提取主干网络, 分别提取主干网络不同尺度的特征。灾前数据不同阶段的特征 S_1, S_2, S_3 ; 灾后数据的不同阶段的特征 S'_1, S'_2, S'_3 。

$$X = \text{Cat} \begin{pmatrix} \text{Cov}(\text{Cat}(S_1, S'_1)) \\ \text{Cov}(\text{Cat}(S_2, S'_2)) \\ \text{Cov}(\text{Cat}(S_3, S'_3)) \end{pmatrix} \quad (1)$$

$$X' = \frac{1}{1 + e^{-\text{Cov}(\frac{TXT^T - \mu}{b})}} \quad (2)$$

式中, T 是关于 Δw , Δh , Δs 的转换矩阵, X 是从震灾前后的数据中提取的纠缠特征。从 X 中选择匹配特征 X' , 表示为 $X \xrightarrow{T} X'$ 。当数据为 $\{X'_{w,h}, X_{w,h}, Y_{w,h}\}$ 时, 使用 Δw , Δh , Δs 标签训练 T 进而得到 X' 。当数据为 $\{X'_{w,h}, Y_{w,h}\}$, $X'_{w,h}$ 经过矩阵转换网络 $X' \xrightarrow{T} X'$, 并使用结构相似函数评估 $X'_{w,h}$ 与 $Y_{w,h}$ 相似性进而微调关于 T 的模型参数。当数据为 $\{X_{w,h}, Y_{w,h}\}$ 时, 先 $X \xrightarrow{T} X'$, 并使用结构相似函数评估 $X'_{w,h}$ 与 $Y_{w,h}$ 的相似性, 粗略对齐 $X'_{w,h}$ 与 $Y_{w,h}$ 的结构特征。 $X'_{w,h}$ 进入下一轮微调对齐训练, 不断迭代致使特征对齐模块收敛。




图6 EDBRDM整体流程图(Backbone表示特征提取模块;OFAM表示目标特征对齐模块;FDCM表示特征差异计算模块;OBCPB表示目标边界约束的位置框检测模块; $\mathcal{L}$ 表示模型的整体损失函数, $\mathcal{L}_a$ 特征对齐损失函数, $\mathcal{L}_b$ 目标边界约束函数, $\mathcal{L}_{\text{cls}}$ 目标类别损失函数, $\mathcal{L}_{\text{box}}$ 目标位置框损失函数, $\mathcal{L}_{\text{conf}}$ 目标置信度损失函数)

Fig. 6 The overall flow chart of EDBRDM (Backbone represents the feature extraction module; OFAM represents the object feature alignment module; FDCM represents the feature difference calculation module; OBCPB represents object boundary constraint-based position box detection module; $\mathcal{L}$ represents the overall loss function of the model, $\mathcal{L}_a$ represents the feature alignment loss function, $\mathcal{L}_b$ represents the object boundary constraint function, $\mathcal{L}_{\text{cls}}$ represents the object category loss function, $\mathcal{L}_{\text{box}}$ represents the object location box loss function, and $\mathcal{L}_{\text{conf}}$ represents the object confidence loss function)




图7 目标特征对齐模块

Fig. 7 Target feature alignment module

4.2 特征差异计算模块

由于遥感图像中目标特征小且差异性不明显,对于损坏房屋的特征难以区别。为了从震灾前后数据中提取损坏建筑物的目标特征。我们设计了特征差异计算模块FDCM。在图8中,描述了特征

差异计算模型的网络结构,从图8中可以看出差异特征信息包含3部分:一是灾前后数据的直接作用差异计算,二是灾前后数据融合特征信息与灾前数据的差异计算,三是灾前后数据融合特征信息与灾后数据的差异计算。3部分汇聚成灾前后数据在保留目标特征基础上的整体差异特征,利用该模块强化损坏建筑的目标特征信息。其主要思想可以表示为: $X \cup \overline{X} \cap Y$, X, Y 表示由OFAM处理的震灾前后数据。首先学习震灾前后数据的整体信息,再使震灾前后数据合并震灾前数据与整体信息的差异特征,致使震灾前后数据进行了差异特征强化融合。FDCM使震灾前后数据互学习特征,形成带有差异信息的目标特征。

特征差异计算模型的具体步骤如下:

FDCM具体流程:

(1) 灾前后数据融合特征:

$$S_0 = \text{Cat}(X, Y) \quad (3)$$

(2) 使用 1×1 卷积进行通道降维:

$$S_1 = \text{Cov}_{1 \times 1}(S_0) \quad (4)$$

(3) 灾前后数据的直接作用差异特征:

$$D_1 = \frac{1}{1 + e^{(X-Y)}} \quad (5)$$

(4) 融合特征与灾后数据的差异:

$$D_2 = \frac{1}{1 + e^{(S_f - Y)}} \quad (6)$$

(5) 融合特征与灾前数据的差异:

$$D_3 = \frac{1}{1 + e^{(S_f - X)}} \quad (7)$$

(6) 差异特征与灾后数据的融合:

$$Y' = \text{Cat}(D_1, D_2, D_3, Y) \quad (8)$$

(7) 使用 1×1 卷积进行通道降维:

$$M = \text{Conv}_{1 \times 1}(Y') \quad (9)$$

以上给出了特征差异计算的详细的描述。 S_0 表示震灾前后数据融合特征, D_i 表示震灾前后数据的差异特征, M 表示震灾后数据融合差异信息的特征。并在图 9 中绘制了特征差异计算的过程。




图8 特征差异计算模块

Fig. 8 Feature difference calculation module




图9 特征差异计算过程

Fig. 9 Feature difference calculation process

4.3 基于目标边界约束的位置框检测模块

深度模型对图像的特征提取了丰富的特征, 其中的边界特征在浅层次体现, 深层次边界特征被抽象特征代替。在图 10 中展示了图像中目标边界特征可视化。预测目标位置是根据目标与锚框

偏移的预测信息计算而来, 在大尺度图像上目标特征尺度小, 经过深度网络提取特征, 相邻的目标特征会出现干扰, 进而影响目标位置检测。我们的想法是将浅层的边界特征引入到深层特征, 为位置和类别预测提供边界约束的作用, 因此本

文提出了基于目标边界约束的位置框检测模块 OBCPB。该方法是先通过像素级别的预测目标的边界区域, 在根据边界约束来预测目标位置及类型, 如图 11 所示。




图 10 目标边界特征可视化

Fig. 10 Visualization of object boundary feature




图 11 基于目标特征边界约束的位置预测

Fig. 11 Object feature boundary constraint-based position prediction

OBCPB 模块的数学形式表示为

$$\mathbf{M}_b = \text{Cov}(\mathbf{S}_0) \quad (10)$$

$$\mathbf{M}_o = \mathcal{F}(\mathbf{M}, \mathbf{M}_b) = \mathbf{M} * \mathcal{W}(\mathbf{M}_b) + \mathbf{M} * (1 - \mathcal{W}(\mathbf{M}_b)) \quad (11)$$

式中, $\mathbf{M}_b$ 表示边界特征, 是由浅层特征 $\mathbf{S}_0$ 经过卷积提取的特征与目标边界多边形框标签进行计算损失进而逼近得到的边界特征。 $\mathbf{M}$ 是特征差异计算模型融合差异信息的特征, $\mathbf{M}_o$ 表示目标融合边界信息的特征。

4.4 损失函数

为了优化本文设计的模型, 使用特征对齐损失、边界相似度量损失和类型位置预测损失进行训练模型。其中特征对齐损失 $\mathcal{L}_a$ 可以表示为

$$\mathcal{L}_a = \frac{\mathcal{L}_{\Delta w, \Delta h, \Delta s} \times is_l + is_{nl}}{\mathcal{S}_{\text{SIM}}(F, \text{Cov}(F'_{wh}))(\mathcal{S}_{\text{SIM}}(F, \text{Cov}(F'_{wh})) \times is_l + is_{nl})} \quad (12)$$

式中, $\mathcal{L}_{\Delta w, \Delta h, \Delta s}$ 表示预测 Δw , Δh , Δs 的交叉熵损

失函数。 is_l 表示数据有对齐标签, is_{wh} 表示数据无对齐标签, $\mathcal{S}_{\text{SIM}}$ 是结构相似度量函数, F_{wh} 表示灾前数据对齐的特征, F'_{wh} 表示灾前数据对齐的微调特征。边界相似度量损失表示为

$$\mathcal{L}_b = \mathcal{D}(\mathbf{M}_b, \mathbf{L}_b) \quad (13)$$

式中, $\mathbf{M}_b$ 表示边界特征, $\mathbf{L}_b$ 表示目标多边形边界标签。类型、位置及置信度的损失表示为: $\mathcal{L}_{\text{cls}}$, $\mathcal{L}_{\text{box}}$, $\mathcal{L}_{\text{conf}}$ 。整体损失函数 $\mathcal{L}$ 表示为

$$\mathcal{L} = \mathcal{L}_a + \mathcal{L}_b + \mathcal{L}_{\text{cls}} + \mathcal{L}_{\text{box}} + \mathcal{L}_{\text{conf}} \quad (14)$$

5 实验与分析

5.1 实验设置

(1) 数据集及实验平台设置。本文设计的模型在数据集 UEDB 上进行了训练及测试。数据集及按照 7:2:1 比例划分为训练集, 测试集及验证集。训练集和测试集的地震数据来源于同一个地区。为了保证我们的模型适应普遍环境, 验证集添加其他区域的遥感数据, 进而验证模型的鲁棒性和实用性。训练实验环境为搭载 GPU RTX 3090 显卡并安装 windows 10 操作系统的平台。

(2) 模型超参数及评估指标。模型的主干网络使用的是 Darknet53。在实验对比中的基线模型是本文构建的简单处理震灾前后建筑物数据的模型。训练过程中的超参数设置: 学习率为 0.0032, 学习率动量为 0.937, 权重衰减系数为 0.0005, 训练总轮数为 300。对于模型精度评估的指标 AP、Recall、Map@0.5、F1, 本文使用 YOLOv3 评估标准 (Redmon 和 Farhadi, 2018)。

(3) 模型训练设置。本文提出的模型是端到端训练, 其中特征对齐模块对于数据输入的不同有 3 种训练情况: (1) 输入数据为 $\{X'_{w,h}, X_{w,h}, Y_{w,h}\}$, 此时使用 Δw , Δh , Δs 标签训练转换矩阵 T 。(2) 输入数据为 $\{X'_{w,h}, Y_{w,h}\}$ 时, 使用结构相似评估函数微调训练 T , 此时无标签训练。(3) 输入数据为 $\{X_{w,h}, Y_{w,h}\}$, 使用 T 预测 $X'_{w,h}$, 下一轮进入 (2) 步骤。

5.2 模型实验验证

本文通过特征可视化的角度来解释模型的内部运行原理, 从多角度立体的观察模型中目标特征的变化。首先我们可视化了模型的第一层的不同通道的特征。接着可视化分析了模型不同层的

特征差异。最后，从特征变化角度分析本文提出模块的作用。从图 12 中，可以观察到不同通道的特征较为丰富，对于下游网络处理单元提供了足够

的特征信息。但由于任务的单一，所需特征信息会在上游丢失。因此，我们提出了 3 个特征处理的模块，使上游的特征得到充分地利用。




图 12 目标特征在同层级不同通道的可视化
Fig. 12 Visualization of object features in different channels at the same level

在图 13 中可视化了模型的不同层次的特征，整体上可以观察到目标特征的汇聚，其中不管是目标特征还是背景特征都会在特征图中表达。对于同一特征图我们分别使用 5 种方式计算同一特征的不同表示。对于这些可以通过有效的优化手段了达到我们最终任务的特征，使其可以接近理想的特征状态。在图 10 中，对比了目标边界特征信息和目标类别位置特征信息，边界信息是在图像固有的特征属性，从第一层网络特征中可以

观看到。对于类别和位置这类比较抽象的特征信息是从边界区域等其他特征抽象学习来的。一般的目标检测是直接的通过抽象学习特征，这样会出现目标位置重叠，相邻的目标只被预测出一个位置信息，也会出现仅预测到了目标部分区域的现象。因此，本文加入了目标特征边界约束，使其学习的类别和位置信息是通过边界信息约束得到，模型检测的位置结果可以稳定在一定范围内。




图 13 目标特征在不同层级特征图的可视化
Fig. 13 Visualization of object feature at different levels

5.2.1 特征对齐验证

为验证特征对齐模块的有效性，可视化了震灾前后数据的对齐特征，如图 14 所示。震灾后数据由于是高清图像，所以灾后数据特征比震灾前数据的特征丰富。由于卷积的特性，震灾前后数据在局部结构上的特征分布对齐即可。因此我们设计了特征结构对齐的评估指标：

$$a_s = \alpha \mathcal{S}_{\text{sim}}(X, 2Y - X) \tag{15}$$

在表 1 中对比不同指标下的特征对齐评估，并在表 2 中展示了特征对齐模型的性能。表 2 中显示该模块对于 AP 值没有起到提升作用，其他指标提升也仅在 10% 以内。这是因为该模块需要与特征差异计算模块一同使用，单独使用对于目标检测任务的作用贡献不大。在实验过程中该模块之后需要震灾前数据特征融合，在本次实验中使用特征相加融合进行实验，来验证该模块的收敛性和稳定性。




图 14 目标对齐特征可视化。
Fig. 14 Visualization of object alignment feature

表 1 特征对齐评估
Table 1 Feature alignment evaluation

震灾前后数据	a_0	a_1	a_2	a_{s1}	a_{s2}
	0.60	0.35	0.25	0.21	0.13
	0.58	0.42	0.34	0.23	0.17
	0.51	0.31	0.26	0.20	0.16

注： a_0 表示图像未对齐数值差。 a_1 表示图像对齐数值差。 a_2 表示图像特征对齐数值差。 a_{s1} 表示图像特征对齐结构相似差。 a_{s2} 表示卷积微调特征对齐结构相似差。

表 2 特征对齐模块的性能指标
Table 2 Performance index of OFAM

模型	性能指标			
	AP	Recall	Map@0.5	F1
基线模型	0.6878	0.3782	0.3047	0.1569
+OFAM	0.5035	0.4316	0.4107	0.267

5.2.2 特征差异计算模块验证

特征差异计算模块的作用是计算震灾前后数据的差异进而放大特征差异，使震灾中损坏的建筑物和无损的进行区别检测。在图 15 中展示了震灾前后的建筑物特征以及震灾前后的建筑物的差异特征。在表 3 中列出了使用计算差异特征模块的目标检测模型的性能。




图 15 震灾前后数据的差异特征可视化

Fig. 15 Visualization of difference feature of data before and after earthquake

表 3 特征差异计算模块的性能指标

Table 3 Performance index of FDCM

模型	性能指标			
	AP	Recall	Map@0.5	F1
基线模型	0.6878	0.3782	0.3047	0.1569
+ FDCM	0.6962	0.414	0.3327	0.1885

5.2.3 基于目标边界约束的位置框检测模块验证

基于目标边界约束的位置框检测模块 OBCPB 是独立的，可以单独使用。但训练该模块时需要目标多边形边界标签，其标注比较费时费力，本

文使用的 UEDB 数据集已经提供了建筑物的边界标注。在图 16 展示了 OBCPB 模块处理特征的过程，图中的特征点表示目标抽象的目标位置特征信息，由于目标位置是由锚框偏移差计算得到，因此特征点在特征图上的位置可以表示其位置分布。从图中可以看出每一个特征点会对应一个边界特征，进而将误判成一个目标的特征分解成多个目标特征。在表 4 中列出了 OBCPB 模块的性能测试，在不同性能指标下都有大幅度提升。特征边界约束模块对于密集目标检测有很大帮助，可以避免不同的目标位置框覆盖合并。



图 16 特征边界约束过程中的特征变化

Fig. 16 Feature change in the process of feature boundary constraint

表4 OBCPB 模块性能指标
Table 4 Performance index of OBCPB

模型	性能指标			
	AP	Recall	Map@0.5	F1
基线模型	0.6878	0.3782	0.3047	0.1569
+ OBCPB	0.7237	0.4528	0.4187	0.2483

5.3 模型的指标评估

在表5中展示了模型的整体性能，本文提出模型的精度相对于基线模型提升了20%的精度，达到了86.81%。表5中MMTOD (Devaguptapu等, 2019) 是基于Yolov5 (Kuznetsova 等, 2020) 复现的多模态目标检测算法，并假设震灾前后建筑物是多模态数据，输入模型进而检测目标。为了保证对比实验的可靠性，表5中的模型使用了相同的超参数设置。在图17中展示了不同模型检测效果对比。在图18、图19中验证了模型在不同尺度场景中的检测结果，对于受损的建筑物可以准确得检测。在表6中，测试了模型在不同平台上的运行速度。最后，又在其他区域收集的数据上进行了验证，如图20所示。在仅使用震灾后数据时模型的精确

度可以达到78%，这是由于轻度损坏的建筑物（如图20中黄色框）相对于无损目标的特征差异小，易出现误检情况（如图20中黑色框区域）无损坏的建筑物被误检。

表5 EDBRDM 的性能指标
Table 5 Performance index of EDBRDM

模型	性能指标			
	AP	Recall	Map@0.5	F1
基线模型	0.6878	0.3782	0.3047	0.1569
Yolov5	0.6683	0.4257	0.3206	0.1890
MMTOD	0.7458	0.4337	0.4094	0.2461
EDBRDM	0.8681	0.7038	0.7068	0.5733




图17 不同模型检测震灾建筑物结果对比

Fig. 17 Comparison of models detection results




图18 大尺度范围内的震灾建筑物检测

Fig. 18 Earthquake-damaged buildings detection in a large scale




图 19 小尺度范围内的震灾建筑物检测

Fig. 19 Earthquake-damaged buildings detection in a small scale

表 6 EDBRDM在应用中的运行速度

Table 6 The running speed of EDBRDM in application

设备	图像大小/像素	时间/(ms/frame)
GPU 2080 Ti	1000—2560	14.43—22.84
GPU 3090	1000—2560	12.97—19.75
CPU	1000—2560	320.41—560.51



图 20 损坏建筑物检测

Fig. 20 Damaged building detection

6 结 论

本文使用无人机收集了一个大规模的震灾建筑物损坏检测的数据集，用于检测地震中损坏建筑物的位置为救灾救援提供技术支持。本文还提出了基于特征对齐、特征差异计算和目标边界约束的建筑物损坏检测模型。并通过实验验证和实

地场景的测试来证明提出模型的稳定性和准确性。该模型具有实时性进而可以和无人机协同工作，边收集数据边检测损坏建筑物，为救援救灾及时反馈信息。本文提出的模型还存在一些不足，如过度依赖震灾前数据，在未使用震灾前数据时模型精度下降了8%。对弱差异目标特征辨别虽然得到了优化，但是依旧存在误检。在实验中轻度损坏建筑物检测受到的影响尤其突出。在应用中可以根据实际情况通过提升目标的置信度阈值过滤一些目标来降低误检率。

志 谢 此次实验的数据中云南彝市地震灾后数据是由云南地震局收集，数据集中的其余数据是由云南师范大学信息学院人工智能和模式识别实验室（PRAI）团队在云南省多个地区收集得到。在此表示衷心的感谢云南地震局、云南师范大学PRAI团队和中国地质资料馆在数据方面提供了帮助和支持。

参考文献(References)

Aamir M, Pu Y F, Rahman Z, Tahir M, Naeem H and Dai Q. 2019. A framework for automatic building detection from low-contrast satellite images. Symmetry, 11(1): 3 [DOI: 10.3390/sym11010003]
Devaguptapu C, Akolekar N, Sharma M M and Balasubramanian V N. 2019. Borrow from anywhere: pseudo multi-modal object detection in thermal imagery//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Long Beach, USA: IEEE: 1029-1038 [DOI: 10.1109/CVPRW.2019.00135]
Dong Y S, Wang R and He J. 2019. Real-time network intrusion detec-

- tion system based on deep learning//2019 IEEE 10th International Conference on Software Engineering and Service Science (ICSESS). Beijing, China: IEEE: 1-4 [DOI: 10.1109/ICSESS47205.2019.9040718]
- Fujita S and Hatayama M. 2023. Estimation method for roof-damaged buildings from aero-photo images during earthquakes using deep learning. *Information Systems Frontiers*, 25(1): 351-363 [DOI: 10.1007/s10796-021-10124-w]
- Gonzalez-Drigo R, Cabrera E, Luzi G, Pujades L G, Vargas-Alzate Y F and Avila-Haro J. 2019. Assessment of post-earthquake damaged building with interferometric real aperture radar. *Remote Sensing*, 11(23): 2830 [DOI: 10.3390/rs11232830]
- Gupta R, Hosfelt R, Sajeev S, Patel N, Goodman B, Doshi J, Heim E, Choset H and Gaston M. 2019. xBD: a dataset for assessing building damage from satellite imagery. *arXiv preprint arXiv*: 1911.09296 [DOI: 10.48550/arXiv.1911.09296]
- Ji S P, Wei S Q and Lu M. 2019. Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1): 574-586 [DOI: 10.1109/TGRS.2018.2858817]
- Kampffmeyer M, Salberg A B and Jenssen R. 2016. Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks// *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Las Vegas: IEEE: 680-688 [DOI: 10.1109/CVPRW.2016.90].
- Kuznetsova A, Maleva T and Soloviev V. 2020. Detecting apples in orchards using YOLOv3 and YOLOv5 in general and close-up images//17th International Symposium on Neural Networks. Cairo: Springer: 233-243 [DOI: 10.1007/978-3-030-64221-1_20]
- Li Q, Wang W, Wang J F, Zhang J F and Geng D. 2021. Exploring the relationship between InSAR coseismic deformation and earthquake-damaged buildings. *Remote Sensing of Environment*, 262: 112508 [DOI: 10.1016/j.rse.2021.112508]
- Mishra B, Garg D, Narang P and Mishra V. 2020. Drone-surveillance for search and rescue in natural disaster. *Computer Communications*, 156: 1-10 [DOI: 10.1016/j.comcom.2020.03.012]
- Nie J Y, Qu S C, Wei Y T, Zhang L M and Deng L Z. 2018. An infrared small target detection method based on multiscale local homogeneity measure. *Infrared Physics and Technology*, 90: 186-194 [DOI: 10.1016/j.infrared.2018.03.006]
- Pulvirenti L, Squicciarino G and Fiori E. 2020. A method to automatically detect changes in multitemporal spectral indices: application to natural disaster damage assessment. *Remote Sensing*, 12(17): 2681 [DOI: 10.3390/rs12172681]
- Redmon J and Farhadi A. 2018. YOLOv3: an incremental improvement. *arXiv preprint arXiv*: 1804.02767 [DOI: 10.48550/arXiv.1804.02767]
- Ren Y, Zhu C R and Xiao S P. 2018. Small object detection in optical remote sensing images via modified faster R-CNN. *Applied Sciences*, 8(5): 813 [DOI: 10.3390/app8050813]
- Sarosa M, Muna N and Rohadi E. 2021. Detection of natural disaster victims using You Only Look Once (YOLO). *IOP Conference Series: Materials Science and Engineering*, 1098(3): 032076 [DOI: 10.1088/1757-899X/1098/3/032076]
- Shen Y, Zhu S J, Yang T J N, Chen C, Pan D L, Chen J Y, Xiao L and Du Q. 2021. BDANet: multiscale convolutional neural network with cross-directional attention for building damage assessment from satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5402114 [DOI: 10.1109/TGRS.2021.3080580]
- Wang Y, Yang Y, Wang B S, Wang T, Bu X H and Wang C Y. 2019. Building segmentation in high-resolution remote sensing image through deep neural network and conditional random fields. *Journal of Remote Sensing (in Chinese)*, 23(6): 1194-1208 (王宇, 杨艺, 王宝山, 王田, 卜旭辉, 王传云. 2019. 深度神经网络条件随机场高分辨率遥感图像建筑物分割. *遥感学报*, 23(6): 1194-1208) [DOI: 10.11834/jrs.20198141]
- Wang Z Y, Wang L and Dai B. 2021. Strong-weak feature alignment for 3d object detection. *Electronics*, 10(10): 1205 [DOI: 10.3390/electronics10101205]
- Weiss M, Jacob F and Duveiller G. 2020. Remote sensing for agricultural applications: a meta-review. *Remote Sensing of Environment*, 236: 111402 [DOI: 10.1016/j.rse.2019.111402]
- Yamazaki Y, Premachandra C and Perea C J. 2020. Audio-Processing-Based human detection at disaster sites with unmanned aerial vehicle. *IEEE Access*, 8: 101398-101405 [DOI: 10.1109/ACCESS.2020.2998776]
- Zhang A, Liu X M, Gros A and Tiecke T. 2017. Building detection from satellite images on a global scale. *arXiv preprint arXiv*: 1707.08952 [DOI: 10.48550/arXiv.1707.08952]
- Zheng Z, Zhong Y F, Wang J J and Ma A L. 2020. Foreground-aware relation network for geospatial object segmentation in high spatial resolution remote sensing imagery//*Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, WA, USA: IEEE: 4095-4104 [DOI: 10.1109/CVPR42600.2020.00415]
- Zheng Z, Zhong Y F, Wang J J, Ma A L and Zhang L P. 2021. Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: from natural disasters to man-made disasters. *Remote Sensing of Environment*, 265: 112636 [DOI: 10.1016/j.rse.2021.112636]
- Zhu X Y, Liang J W and Hauptmann A. 2021. MSNet: a multilevel instance segmentation network for natural disaster damage assessment in aerial videos//*Proceedings of the IEEE Winter Conference on Applications of Computer Vision*. Waikoloa, USA: IEEE: 2022-2031 [DOI: 10.1109/wacv48630.2021.00207]

Detection of earthquake-damaged buildings via UAV high-resolution remote sensing images

WANG Haifeng^{1,2}, ZHOU Chengjiang^{1,2}, CHEN Xuefeng³, YANG Yang^{1,2,4}

1. Information Science and Technology, Yunnan Normal University, Kunming 650500, China;

2. Laboratory of Pattern Recognition and Artificial Intelligence, Yunnan Normal University, Kunming 650500, China;

3. Yunnan Province Center of Relief Material Reserve, Kunming 650300, China;

4. Physics and Electron Information, Yunnan Normal University, Kunming 650500, China

Abstract: Natural disasters occur frequently in Yunnan, China and cause enormous losses of life and property. An object detection technology based on the deep learning of remote sensing images can be used to rapidly locate damaged buildings caused by natural disasters and subsequently aid with disaster relief. However, several challenges affect the detection of damaged buildings, such as the lack of data on earthquake-damaged buildings and the weakness of the features of objects to be detected. Thus, a UAV remote-sensing image-based largescale high-resolution earthquake-damaged building database (UEDB) was constructed. A total of 4598 remote sensing images were collected in the disaster area of Yangbi Yi Autonomous County in Dali Bai Autonomous Prefecture, Yunnan Province, China. The dataset includes 76,012 building instances, with each instance labeled in three formats: an object location box label, an object segmentation label, and an object boundary label. Then, a novel Earthquake-Damaged Buildings Real-time Detection Model (EDBRDM) was constructed. This model includes three modules: object feature alignment (OFAM), feature difference calculation (FDCM), and object boundary constraint-based position box detection. The processing procedure of this model is as follows. Firstly, the OFAM correct the misalignment issues in images taken before and after a disaster, ensuring precise alignment of object features. This crucial step forms the foundation for subsequent feature analysis and difference calculation. Secondly, the FDCM is employed to compute the differences in features, highlighting the damage characteristics of buildings. By comparing the image features before and after the disaster, we can more clearly identify the damage of buildings, providing strong support for subsequent identification and analysis of damaged buildings. Lastly, the OBCPB introduces shallow boundary features into deep features, providing boundary constraints for the prediction of damaged building locations and categories. This step helps enhance detection accuracy, ensuring that we can accurately identify and locate damaged buildings. Through the collaborative effort of these three steps, we can achieve precise detection of damaged buildings. To validate the crucial role of the proposed modules, we delve into the internal operating principles of the model through the lens of feature visualization. Firstly, by comparing the feature changes after OFAM processing, we can clearly observe the significant improvements in the alignment of features across pre- and post-disaster images, demonstrating the effectiveness of OFAM in correcting image offsets. Secondly, by observing the enhancement of damaged building features by FDCM, we find that it effectively highlights the damaged areas of buildings, providing strong support for subsequent identification and analysis of damaged buildings. Finally, through the observation of the boundary constraint effect of OBCPB, we can see how it helps to improve the localization accuracy of the model, ensuring that damaged building objects can be accurately identified. It is noteworthy that our proposed model, EDBRDM, has achieved a remarkable accuracy of 86% on the UEDB test dataset, fully demonstrating its excellent performance. Furthermore, the application of EDBRDM to actual scenes in different locations has also yielded satisfactory results, further validating its effectiveness and reliability in practical applications.

Key words: deep learning, high-resolution remote sensing images, object detection, change detection, earthquake disaster

Supported by National Natural Science Foundation of China (No. 41971392); Yunnan Ten-Thousand Talents Program; Postgraduate Research Innovation Fund Project of Yunnan Normal University (No. ysdjys2020148)