

遥感目标灾害智能评估技术进展与挑战

张伊丹^{①②③④} 冯瑛超^{*①④} 王天琦^{①②③④} 刘煜^{①②③④}
王萌雨^{①②③④} 侯钟砚^{①②③④}

^①(中国科学院空天信息创新研究院 北京 100190)

^②(中国科学院大学 北京 100190)

^③(中国科学院大学电子电气与通信工程学院 北京 100049)

^④(目标认知与应用技术国家级重点实验室 北京 100190)

摘要: 随着全球自然灾害频发以及各类突发事件风险上升,如何依托智能遥感技术对受灾目标开展快速、精准的评估,已成为支撑应急响应与灾后重建的重要任务。近年来,基于深度学习的遥感灾害评估方法不断涌现,大大提高了灾害评估的精度和智能化程度,然而,该领域发展迅速但仍缺乏系统性综述。本文全面梳理了遥感目标灾害智能评估的技术内涵;对现有研究中常用的目标损伤等级标准、公开数据集及性能评价指标进行了归纳;围绕双时相变化检测、多时相序列建模、多模态数据融合、数据受限场景下灾害评估四类技术框架进行深入分析,叙述了各类方法的技术路径及其优势与不足;最后,本文进一步探讨了该领域未来的发展方向,旨在为遥感智能灾害评估技术在人为及自然灾害应对中的应用提供理论支持与方法参考。

关键词: 灾害评估; 遥感影像; 深度学习

中图分类号: TN911.7

文献标识码: A

文章编号: 1009-5896(2026)00-0001-16

DOI: 10.11999/JEIT251297

CSTR: 32379.14.JEIT251297

1 引言

遥感解译与计算机视觉技术的深度融合^[1],正持续推动灾害评估从专家驱动的人工判读向数据算法驱动的智能化范式转型。在自然灾害、地区冲突等突发事件中,受灾目标的损伤情况直接影响应急响应效率、资源科学调配与重建策略的实施效果。因此,如何实现受灾目标的高效精准识别与损伤等级划分,成为智能遥感分析领域的关键问题。

传统灾害评估主要依赖卫星影像人工判读,存在主观偏差大、响应延迟高、跨场景泛化弱等固有缺陷,难以满足灾后精准、高效评估的需求。近年来,卷积神经网络(Convolutional Neural Networks, CNN)、Vision Transformer(ViT)及其变体等深度学习技术显著提升了遥感灾害评估的自动化程度与精度^[3-7]。更进一步,多时相序列建模(如损伤过程时序演化追踪)、多模态遥感数据融合(如光学与合成孔径雷达影像协同)与数据受限条件下的

鲁棒方法(如伪标签、迁移学习)等技术,有效增强了评估方法的鲁棒性与泛化能力。我们基于“灾害评估+深度学习+遥感影像”等关键词,在WoS(Web of Science)和中国知网(China National Knowledge Infrastructure, CNKI)进行文献搜索。统计结果如图1所示,相关研究的发文数量整体呈逐年增长趋势,表明该领域研究关注度不断提高。

本文系统梳理了目标遥感灾害智能评估的技术框架,剖析现有方法的优势与局限,并提出针对性研究发展建议。全文结构如下:第2章阐述任务定义与技术内涵、目标损伤等级分类体系、数据集和评价指标;第3章归纳四类代表性技术框架;第4章展望未来研究方向。

2 任务概述

本节首先系统阐述了遥感图像中目标灾害智能评估的任务定义与核心技术内涵;接着介绍了目标损伤等级分类的体系,包括自然灾害和人为灾害不同灾害类型的特点,以及它们的损伤等级分类标准;最后,本文对目前主流的遥感灾害评估公开数据集进行了归纳整理,并介绍了衡量模型性能的常用评价指标。

2.1 任务定义与技术内涵

遥感目标灾害智能评估的核心任务是通过分析遥感图像,提取目标特征及其受损特征,并输出目标的定位信息与受损等级。其主要包含两个关键子

收稿日期: 2026-xx-xx; 改回日期: 2026-07-02; 网络出版: 2026-07-12

*通信作者: 冯瑛超 fengyc@aircas.ac.cn

基金项目: 国家重点研发计划(2024YFF1401001), 国家自然科学基金(62301538), 空天院科学与颠覆性项目资助(2025-AIRCAS-SDTP-04)

Foundation Items: National Key R&D Program of China (2024YFF1401001), National Natural Science Foundation of China (62301538), The Science and Disruptive Technology Program, AIRCAS (2025-AIRCAS-SDTP-04)




图 1 基于深度学习的遥感目标灾害评估研究相关文献统计

任务：目标定位与损伤等级分类，二者紧密耦合，可形式化为双阶段联合优化问题。

2.1.1 任务分解

子任务1是目标定位。目标定位以灾前图像为输入，生成定位掩码，其中像素值为非0值，表示目标存在，0表示背景区域。该任务是后续损伤等级分类的基础，需通过语义分割技术实现高精度定位。

子任务2是损伤等级分类。该任务是在目标定位基础上，以灾前-灾后图像对和定位掩码作为输入，输出多类别掩码，其中每个像素或对象对应不同的损伤等级，例如未损伤、轻度损伤、重度损伤、完全损伤。对于像素级别的研究，应确保同一目标内的所有像素具有一致的损伤等级，以保证分类结果在空间分布上的一致性，从而提高评估的准确性和合理性。

2.1.2 数学建模框架

设灾前影像为 $\mathbf{X}^{(t_0)} \in \mathbb{R}^{H \times W \times C}$ ，灾后影像为 $\mathbf{X}^{(t_i)} \in \mathbb{R}^{H \times W \times C}, i = 1, 2, \dots, I$ ，其中 H, W, C 分别表示图像的高度、宽度和通道。评估模型为 $\mathcal{M} = [\mathcal{M}_{\text{loc}}, \mathcal{M}_{\text{dam}}]$ 。模型在第一阶段目标定位的输出为灾前建筑掩码 $\mathbf{Y}_{\text{loc}} = \mathcal{M}_{\text{loc}}(\mathbf{X}^{(t_0)}) \in \{0, 1, \dots, N\}^{H \times W}$ ，0表示背景，1到N分别对应不同目标类别或不同目标实例；在第二阶段损伤分类的输出为灾后损伤等级掩码 $\mathbf{Y}_{\text{dam}} = \mathcal{M}_{\text{dam}}(\mathbf{X}^{(t_0)}, \mathbf{X}^{(t_i)}, \mathbf{Y}_{\text{loc}}) \in \{0, 1, \dots, M\}^{H \times W}$ ，0到 M 分别表示从轻到重的损伤等级。

模型目标函数由定位和损伤等级分类两部分组成：

$$L_{\text{total}} = \lambda_{\text{loc}} L_{\text{loc}}(\mathbf{Y}_{\text{loc}}, \mathbf{Y}^{(t_0)}) + \lambda_{\text{dam}} L_{\text{dam}}(\mathbf{Y}_{\text{dam}}, \mathbf{Y}^{(t_i)}) \quad (1)$$

其中， $\mathcal{L}_{\text{loc}}$ 为定位损失函数， $\mathcal{L}_{\text{dam}}$ 为分类损失函数； $\mathbf{Y}^{(t_0)}$ 和 $\mathbf{Y}^{(t_i)}$ 分别表示用于目标定位和损伤等级分类的目标真实值； λ_{loc} 和 λ_{dam} 分别为目标定位

和损伤等级评估的任务权重系数。模型需最小化联合损失以减小评估误差。

2.1.3 任务内涵

遥感目标灾害评估是一项极具挑战性的综合性任务，其核心在于通过异构、多时相的观测数据，推理目标物理结构及其功能的演化情况，最终得到损伤程度。该任务要求模型不仅要具备对不规则形变的理解能力，还需在应急抢险等部分场景下具备多源信息深度融合与理解能力。为了进一步厘清其技术边界，本文以目标检测任务为例，剖析灾害评估在技术内涵与理论层面面临的特有挑战。

(1)从“静态分类”到“时序演化推理”：目标检测通常在单时相影像上解决“存在性”问题，即提取静态空间特征进行模板匹配或分类。而灾害评估本质上是状态演化建模，关注的是目标在时间维度上的变化增量。这要求模型必须处理灾前、灾后的多时相影像数据，不仅要克服拍摄角度、光照差异、大气环境等非目标变化带来的干扰，还要能够从复杂的背景中准确剥离出由于损伤导致的状态转移特征。

(2)从“共性特征提取”到“异常形变特征分析”：在空间表征层面，灾害评估表现出极强的随机性与不均匀性，这与目标检测任务中强调的“类内一致性”特征提取存在本质区别。损伤造成的视觉特征(如结构坍塌、烧蚀痕迹、边缘破碎)往往不具备固定的几何模式。此外，同一种损伤等级在视觉表现上具有显著的多样性。以桥梁为例，无论是桥面大范围断裂、主桥墩局部坍塌，还是关键支座发生位移，均可被判定为“重度损伤”。这种“同级异构”的特性要求灾害评估的核心不再是提取目标类别的共性特征，而是捕捉目标物理结构相对于原始标准的“偏离程度”。这种范式的转变，要求算法必须对局部微弱的纹理畸变、不规则形变以及关键功能部位的异常具有极高的敏感度。

(3)从“单模态处理”到“跨模态变化评估”：在实际灾害评估场景中，灾前通常可以利用易于获取的高分辨率光学影像，来准确判定目标的地理位置与原始几何形状。然而，灾后评估往往面临极端复杂的现场环境，如地震后烟尘遮蔽干扰，或是夜间突发灾害，导致光学传感器往往无法获取有效影像，必须引入合成孔径雷达(SAR)或红外等异构数据。由于不同传感器的成像机理存在本质差异，灾害评估面临着严峻的跨模态特征对齐挑战。模型需在特征层实现异构数据的一致性映射，利用跨模态物理互补特性(如SAR的穿透性与光学的高分辨率纹理)来还原真实的损伤状况。

遥感影像灾害智能评估任务的核心在于从多时相、多模态的观测数据中，隐式反演挖掘目标状态改变的过程，并最终推断出损伤等级。该任务不仅要求模型实现对异构数据的时序对齐与特征融合，更本质的困难在于，目标的视觉损伤特征与其损伤程度之间存在着复杂的非线性映射关系，这要求模型必须从传统的模式识别，转向深入理解状态变化过程，实现“所见”与“实际”之间的有效耦合。总的来说，遥感影像损伤只能评估是一个值得深入探索且充满挑战的方向。

2.2 损伤等级分类体系

在基于深度学习的灾害评估研究范式下，模型的预测精度在很大程度上依赖于训练数据的标注质量。因此，建立一套科学、规范且具有可操作性的损伤等级分类标准至关重要，这不仅能保证标注数据的一致性和可靠性，还能有效减少因主观判断或标注歧义导致的模型偏差，从而提升灾害评估的客观性和可重复性。当前，相关研究多聚焦于居民区、能源设施及交通枢纽等场景中建筑物的灾害评估，这主要得益于建筑物结构特征明确且数据获取相对便捷。本节将先对典型灾害类型及其对建筑物造成的损伤特征展开介绍，进而阐述损伤等级的分类标准，旨在为后续的数据集制定和模型设计提供理论基础和规范指引。

2.2.1 灾害类型

不同灾害类型的形成机制和原理不同，如表1所示，因此对建筑物的损伤表现也各有特点：地震主要表现为地面震动引起的结构失稳、墙体开裂、倒塌等，常造成建筑物整体性破坏，在影像上表现为屋顶结构大面积塌陷和瓦砾堆积形成的阴影纹理；飓风、台风以强风和暴雨为主要致灾因子，会造成屋顶掀翻、窗户破碎、水浸损坏等局部损伤，其中暴雨引发的城市内涝区域会有镜面反射特征；洪水灾害通常表现为大范围水体覆盖形成的深色均

匀纹理，被淹建筑呈现“孤岛效应”；野火经过区域的建筑可能呈现碳化痕迹和屋顶轮廓扭曲变形；海啸灾害则会导致沿海建筑群定向倒塌，同时海水退却后遗留的盐渍化地表可通过高光谱特征识别；爆炸这类人为灾害通常造成局部高强度冲击波、穿刺、燃烧等直接破坏，建筑物可能出现结构性断裂与功能系统瘫痪，在影像上显示为弹坑的环形辐射状破坏模式，以及建筑屋顶或墙体穿孔所形成的规则阴影等特征。

2.2.2 损伤等级分类标准

目前建筑物常用的遥感灾害评估体系是四级联合损伤等级标准^[2]，其将建筑损伤划分为“无损伤、轻度损伤、重度损伤、完全损伤”四个等级。该标准以联合国卫星应用组织(The United Nations Satellite Centre, UNOSAT)制定的灾害灾害评估指南^[9]美国联邦应急管理局(Federal Emergency Management Agency, FEMA)提出的建筑灾害评估体系^[10]，欧洲宏观地震烈度评估体系(The European Macroseismic Scale, EMS-98)^[12]，以及国际卫星应急测绘工作组(International Working Group on Satellite-based Emergency Mapping, IWG-SEM)提出的应急测绘指南^[13]等多个国际权威标准为基础，结合遥感图像特征与结构安全等级进行统一划分，广泛应用于全球建筑物灾后评估与智能解译任务中^[16,35]。基于此，本文依据不同灾害类型在遥感影像中的典型表现形式，对既有标准中关于建筑损伤等级的判据与描述规则进行了分类归纳与整理说明，并汇总形成表2所示的四级联合损伤等级说明，用于后续评估模型的任务设计与结果判读。

该基于损伤状态的定性分级体系已在UNOSAT、FEMA及哥白尼应急管理服务(Copernicus EMS)等国际应急制图与灾后评估任务中得到长期、广泛应用，他们依据这些规则，由人工或半自动方式将单

表 1 不同灾害类型对比

灾害类型	形成机制	典型灾害事件(2020~2025年)	影响范围
地震	地面震动、剪切波传播	2023年土耳其-叙利亚地震； 2025年缅甸地震	城市建筑不同程度倒塌，人员伤亡，国际救援介入
飓风/台风	强风、暴雨、风暴潮	2020年美国飓风“劳拉”； 2023年台风“杜苏芮”登陆菲律宾/福建	洪水淹城，通讯中断，经济损失巨大
洪水	降水过量、堤坝溃决	2021年河南郑州“7·20”特大暴雨； 2023年中国河北涿州洪灾	地铁被淹、城镇基础设施受灾、 大规模房屋损坏和人员伤亡
野火	干燥高温、引燃源	2023年加拿大野火； 2025年美国洛杉矶山火	森林烧毁，森林周边居民区房屋受灾
海啸	海底地震引发海浪	2021年印尼马鲁古海小型海啸(局地)； 2022年汤加海底火山喷发引发海啸	沿岸建筑受灾，通讯中断， 邻国多地发出预警
地区冲突/爆炸	爆炸、穿甲弹、燃烧弹	巴以冲突；俄乌冲突；伊以冲突	城市废墟化、基础设施毁坏、能源/粮食危机、 难民危机蔓延至多国

体建筑划分为无损伤、轻度损伤、重度损伤和完全损伤等损伤状态，并在区域尺度上汇总形成损伤分布图与统计评估结果，用于支撑应急响应与决策制定。

2.3 数据集与评价指标

2.3.1 数据集

随着遥感技术的不断发展，面向灾害评估的影响数据集逐步丰富，为灾害响应和基础设施安全监测提供了有力支撑。近年来，多个具有代表性的遥感损伤数据集被提出，如表3所示。这6个灾害评估领域的主流数据集涵盖地震、飓风、地区冲突等多种灾害类型，数据模态包括卫星光学、SAR及无人机影像，标注粒度从建筑物级到像素级不等，空间分辨率跨越0.3-1米，为不同场景下的损伤检测研究提供了多样化基准。这些数据集在灾害类型、图像来源、分辨率等方面各具特色，推动了遥感图像灾

害评估技术的发展。

2.3.2 评价指标

在灾害评估研究中，建立科学合理的评估指标体系是衡量模型性能、比较不同方法优劣以及推动技术发展的关键环节。如表4所示，常见的像素级指标包括准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1分数(F1-score)以及交并比(Intersection over Union, IoU)，其中IoU被广泛应用于图像分割类任务，能够有效反映预测损伤区域与真实标签之间的空间重合度；F1分数则结合了精确率与召回率的优势，能够评价模型综合能力。在实际灾害评估任务中，仅依赖单一维度的评价指标往往难以全面刻画模型性能，模型既需要具备准确的目标定位能力，又需要在此基础上正确判别损伤等级。为综合反映模型在定位与损伤判定两个关键环节上的整体表现，部分研究在分析阶段引入了加权

表 2 四级联合损伤等级标准

损伤等级	地震	飓风/台风	洪水	野火	海啸	爆炸
无损伤	未受影响。					
轻度损伤	表面裂缝、非结构构件损伤，结构基本完整。	屋顶覆盖物(瓦片、金属板、防水层)局部损坏或掀起。	建筑底部或周边出现短期、浅层积水。	建筑外立面或屋顶局部烧蚀，主体结构保持稳定。	外立面或非承重构件受冲刷或撞击。	建筑局部出现破孔或外立面损伤。
重度损伤	明显结构性破坏，部分构件失效或局部坍塌。	屋顶大面积掀翻或结构性破坏，功能严重受限。	建筑长时间被洪水或泥水包围，发生明显侵蚀。	大面积烧毁，发生明显结构损伤。	承重墙、楼板或基础发生明显结构性破坏，屋顶、楼板或坏，功能基本丧失。	建筑出现大范围结构破坏，屋顶、楼板或承重墙部分坍塌。
完全损伤	建筑整体或近乎整体倒塌，结构完全失效。	主体结构不复存在，无法继续使用修复。	完全被积水/泥水覆盖，主体严重破坏。	建筑整体烧毁，仅残留地基或局部残骸。	建筑被整体冲毁、掀走或完全倒塌。	建筑整体倒塌、消失或不可识别。

表 3 常见数据集介绍

名称	灾害类型	图像模态	图像来源	标注类别	图像数(张)	图像尺寸/分辨率(米)	受灾地区
xBD ^[8] (2019)	地震/海啸、洪水、飓风、野火、火山喷发	卫星光学图像	Maxar数字地球开放数据计划	5类：背景、无损伤、轻度损伤、重度损伤、完全损伤	22068	1024×1024 / 0.5-0.8	美国、印度尼西亚、菲律宾等全球15个国家的受灾地区
Ida-BD ^[16] (2022)	飓风	卫星光学图像	WorldView-2卫星	5类：背景、无损伤、轻度损伤、重度损伤、完全损伤	174	1024×1024 / 0.5	美国路易斯安那州新奥尔良部分区域
RescueNet ^[17] (2023)	飓风	无人机光学图像	机器人辅助搜救中心(小型无人机系统)	10类：背景、水、无损伤建筑、中度损伤建筑、重度损伤建筑、完全损伤建筑、车辆、树、水池、阻塞道路	4494	3000×4000 / —	美国佛罗里达州墨西哥海滩附近
QQB ^[18] (2024)	地震	卫星光学与SAR图像	WorldView-3卫星/Capella Space的GEO产品	2类(建筑物级别，不是像素级别)：无损伤、有损伤	16116	建筑物大小 / SAR: 0.35 光学: 0.31	土耳其、叙利亚
BRIGHT ^[19] (2025)	地震、洪水、海啸、火山喷发、野火5种灾害，地区冲突、爆炸2种人为灾害	卫星光学图像与SAR图像	Maxar数字地球开放数据计划/Capella Space雷达卫星/Umbra卫星	4类：背景、无损伤、有损伤、完全损伤	4246	1024×1024 / 0.3-1	土耳其、墨西哥、缅甸等全球14个国家的受灾地区
WCP ^[20] (2023)	地区冲突	卫星光学图像	哨兵-2号卫星、Google earth影像	3类：背景、无损伤、有损伤	81	120×120, 6×6, 3×3 / 0.5, 10	6个叙利亚城市和4个乌克兰城市

复合评价指标，将定位性能指标 F_1^{loc} 和损伤等级分类性能指标 F_1^{dam} 加权结合，形成综合评分 $F_1^{overall}$ 。

3 遥感目标灾害评估方法

深度学习技术的兴起极大推动了遥感目标灾害评估方法的发展^[21,24]相较于传统的基于专家知识的灾害评估方法^[25]，深度学习使模型具备了端到端自动学习特征的能力，摆脱了手工特征设计的限制，能感知灾前灾后图像间的复杂差异，还能对损伤等级进行细粒度区分，因此在大规模遥感图像数据上

的性能表现得到了显著提升。

本文将遥感目标灾害智能评估技术分为四类，如图2所示，双时相变化检测方法通过对比灾前灾后双时相影像实现灾害评估，具有计算高效、部署灵活的特点；多时相序列建模方法则进一步利用连续时间序列数据捕捉动态损伤过程，特别适用于评估渐进性损伤；此外，针对复杂场景的感知需求，多模态遥感数据方法融合光学、SAR、LiDAR等多源数据，通过跨模态特征互补解决单一数据的局

表 4 常用评估指标

指标	计算公式	意义
	$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$	
准确率 (Accuracy)	TP为真正例：被模型预测为正类的正样本 TN为真反例：被模型预测为负类的负样本 FP为假正例：被模型预测为正类的负样本 FN为假反例：被模型预测为负类的正样本	衡量模型预测正确的比例， 反映灾害评估模型的总体能力
精确率 (Precision)	$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$	在所有被模型预测为损伤的目标中，实际为损伤的比例， 强调“误报率”低
召回率 (Recall)	$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$	在所有真实损伤目标中，被模型成功识别出来的比例， 反映“漏报率”低
F1分数	$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$	精确率与召回率的调和平均值，综合评估模型预测的 准确性与完整性
交并比 (IoU)	$\text{IoU} = \frac{ \text{A} \cap \text{B} }{ \text{A} \cup \text{B} }$ A: 预测区域像素集合 B: 真实区域像素集合	损伤识别结果与实测损伤区域的空间重叠质量， 能够反映模型定位准确性
平均精度 (mAP)	$\text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i$ AP _i 是第 <i>i</i> 类别的平均精度	表示多类别下精确率-召回率曲线的平均面积， 反映模型多类别识别与定位的综合能力
覆盖率	$\text{Coverage} = \frac{\text{CorrectlyIdentifiedArea}}{\text{TotalDamageArea}}$	正确识别出的损伤区域在总损伤区域中的占比， 体现模型空间识别完整性
地理定位误差	$\text{Error} = \sqrt{(x_{\text{pred}} - x_{\text{true}})^2 + (y_{\text{pred}} - y_{\text{true}})^2}$ ($x_{\text{pred}}, y_{\text{pred}}$)是预测坐标 ($x_{\text{true}}, y_{\text{true}}$)是真实坐标	预测中心与真实中心的欧氏距离， 衡量模型对损伤目标位置的定位精度
推理效率(FPS)	$\text{FPS} = \frac{N}{T}$ <i>N</i> 为处理的图像(或样本)数量， <i>T</i> 为对应的时间	衡量模型在给定硬件与输入条件下的推理速度，反映其在 大范围灾区快速评估与应急响应场景中的实际部署效率

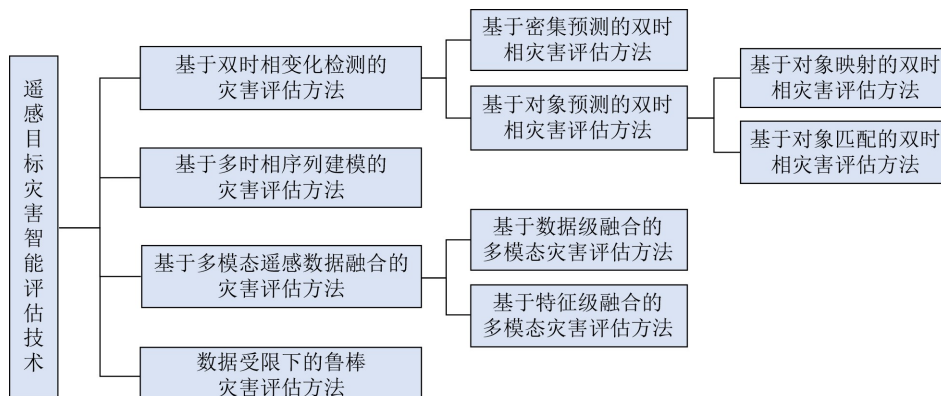


图 2 遥感影像目标灾害智能评估技术分类

限性；最后，面向实际应用中标注数据稀缺和跨域泛化挑战，数据受限下的鲁棒评估方法采用小样本学习、域适应等技术，显著提升了模型在新区域或新灾害类型下的迁移能力。其中，基于双时相变化检测的方法最为常用且研究最为成熟，其余三类方法则作为有力补充，分别应对多时相建模、多源信息融合以及数据稀缺等挑战，共同构建了从基础变化检测到复杂场景应用的完整技术体系。

3.1 基于双时相变化检测的灾害评估方法

在基于遥感图像的目标灾害评估任务中，通常通过对比灾前与灾后两幅遥感图像，识别图像中发生变化的区域，从而判断目标是否损伤以及损伤等级。与只使用灾后图像这种单一时相的方法^[28,29]相比，双时相方法能为模型提供更完整的语义与空间先验信息，更适合捕捉从“未损伤”到“损伤”的动态过程，而且双时相有助于消除光照条件、模糊遮挡等非相关因素的干扰，提高对目标的识别能力。

依据输出目标的不同，基于双时相变化检测的

灾害评估方法可以划分为密集预测方法和对象预测方法，如图3所示。前者以每个像素为预测单元输出损伤等级，实现精细的像素级损伤预测；后者则结合目标检测或实例分割技术，先定位单体对象再整体判断其损伤程度，具有更高的语义一致性与结果可解释性。两类方法各有侧重，相互补充，构成了当前基于双时相变化检测的遥感灾害评估研究的核心内容。

3.1.1 基于密集预测的双时相灾害评估方法

基于密集预测的方法是当前最为主流、应用最广泛的技术路线，该方法对灾前与灾后图像进行像素级别的目标定位与损伤分类，具体流程如图4所示。首先，将灾前和灾后两幅遥感图像分别输入权值共享的特征提取模型，这种双流孪生编码器的结构通过网络架构相同、参数共享的方式来提取出具有相同语义尺度与结构信息的特征表示；随后，这些特征被送入两个下游任务模块，分别用于目标定位和损伤等级分类；最终输出像素级的定位结果和分类结果，实现损伤区域的检测与分级，具备细粒




图3 基于密集预测和对象预测的灾害评估对比图




图4 基于密集预测的灾害评估框架

度、可解释的空间表达能力。近年来的大量研究几乎都围绕这一方法展开,且在不断探索更高精度和更强鲁棒性的模型架构。

在网络结构方面, CNN是最早应用于遥感灾害评估任务的深度学习网络架构,它具有局部感知和参数共享的特点,特别契合灾后遥感图像中建筑倒塌、碎片堆积、地表破坏等局部非结构化特征显著的灾害场景,许多基线方法(如xView2官方模型^[8]、Siam-U-Net^[30]等)都构建在CNN架构之上。该类方法通过卷积的方式逐层提取图像的多尺度特征,能够有效捕捉损伤边界、破坏形态和纹理突变区域,从而实现对受灾区域的精准检测。相比于传统方法,基于CNN的模型在特征表达能力上具有显著优势,能够解决复杂背景和遮挡干扰下损伤区域边界难以精确分割的问题,能够适应不同灾害类型下的多样化损伤表现,满足灾害评估对准确定位和精准损伤等级分类的需求。随着Vision Transformer (ViT)及其变体的发展,研究者逐步将Transformer应用于损伤检测任务,提出了如BAT^[31]、SLgViT^[32]、MDA-CD^[33]等模型。对于大范围灾区高分辨率遥感图像中同时包含轻微破坏和严重破坏区域的场景,传统CNN容易出现局部视野不足、难以建模跨区域破坏关联等问题。Transformer模型以其全局建模能力能够捕捉双时相影像中的长距离变化依赖、微小结构变化与全局破坏模式,在处理大尺寸图像和复杂损伤空间分布时展现出更强的差异捕捉和结构理解能力。尽管自注意力机制带来了强大的全局视野,但其计算复杂度与图像序列长度的平方成正比,这意味着随着传感器分辨率的提升,显存消耗将呈指数级增长。Mamba^[34]结构进一步解决了Transformer在灾区大图处理时计算和内存消耗过高的问题。它用状态空间序列模型替代注意力机制,具备更高效的长序列处理能力,其核心模块是选择性扫描机制,在扫描过程中,模型能根据像素特征动态调节“记忆”权重,自动过滤冗余的植被或背景信息,并精准强化对灾后碎片、裂缝等关键损伤特征的提取。这种机制使得模型在保持全局建模优势的同时,显著降低了计算与内存成本,更适合在灾后应急快速评估中部署。目前Mamba在遥感灾害评估中的应用尚处于探索阶段,但Chen等人^[35]的研究已表明其在灾害评估任务中具有优异表现,加快了对大幅面灾区遥感影像中损伤区域的快速推理与识别,满足紧急救援和快速响应场景下的效率需求。

综上,基于密集预测的双时相灾害评估已形成以CNN、Transformer和Mamba为代表的多类

主干框架,分别从结构优化、全局建模和高效推理等方面,持续应对损伤边界模糊、形态多样、分布复杂及效率不足等问题。尽管该类方法取得了显著进展,但其局限也较为明显:一方面,以像素为基本单元的推理方式缺乏对地物拓扑结构和物理完整性的约束,易产生“椒盐噪声”,同一目标内部甚至出现割裂且矛盾的损伤判定,往往依赖后处理进行聚合;另一方面,其对全图像素逐一提取特征,包含大量背景冗余,在超高分辨率影像下会带来较大的计算与显存开销。因此,研究者开始转向基于对象预测的双时相灾害评估方法,以提升模型的泛化能力和实用性。

3.1.2 基于对象预测的双时相灾害评估方法

基于对象预测的方法可以克服像素空间不连续和无法考虑上下文信息的缺陷,通过将像素分割成独立的对象并比较它们的差异来直接获得对象级别的评估结果。基于对象预测的灾害评估方法通常将整个评估过程划分为两个阶段,首先利用目标检测算法(如Faster R-CNN^[37]、YOLOV10^[38]等)或实例分割方法(如Mask R-CNN^[39]、Mask2Former^[40]) 在灾前和灾后图像中识别并定位出感兴趣的对象;随后,提取对象在灾前与灾后图像中的变化特征,对每一个已检测出的对象进行损伤等级分类。该方法以“先定位、后分类”为基本流程,具备更强的目标级语义一致性和结果可解释性。

根据对象检测方式的不同,本文将基于对象预测的双时相灾害评估方法分为基于对象映射的双时相灾害评估方法与基于对象匹配的双时相灾害评估方法。(1)基于对象映射的双时相灾害评估方法^[41],如图5(a)所示,仅对其中一幅影像执行目标检测/实例分割后生成对象,并将分割边界映射到另一幅影像,再通过深度学习网络从双时相影像中提取变化信息确定每个对象的损伤等级。然而,这种映射机制对空间配准精度具有极强的依赖性。由于卫星拍摄角度导致的投影差或地形起伏引起的局部畸变,极易导致灾前后特征采样区域发生语义错位,进而引发严重的误判。(2)基于对象匹配的双时相灾害评估方法^[42,43],如图5(b)所示,首先使用权重共享的目标检测/实例分割模型对灾前和灾后图像分别进行对象的检测,获得每个时相下的空间对象集合。随后,通过匹配两个时相中的对象来分析灾前灾后的变化(如对象是否消失、是否损伤、损伤程度)来判断损伤情况。这种方式的优点在于结构清晰,但缺点是跨时相语义对齐较难,易受配准误差与细节差异影响,特别是在极端损伤场景下,灾前清晰的建筑轮廓在灾后可能转化为散乱的瓦砾,




图 5 基于对象预测的灾害评估框架

导致检测器在灾后时相中出现置信度下降或形状严重畸变，导致匹配失败。

一些方法如ChangeOS^[44]、ESCNet^[45]、S3Net^[46]虽然输出了对象级别的评估结果，但它们的基本研究单位仍然是像素，对象级的结果是经由后处理得到的。目前真正的基于对象的双时相灾害评估方法的研究相对较少，主要是因为这种方法存在精度受限、对象提取的准确性、模型复杂度高、标注成本高等问题。首先，该方法的性能高度依赖于第一阶段对象提取的准确性。如果对象提取阶段出现误检、漏检或边界不准确等问题，将直接导致后续评估出现对象缺失或掩码错误等问题，难以弥补。其次，对象级建模过程的网络结构更为复杂，与像素级方法直接进行密集预测不同，对象级方法需要依次完成目标检测或实例分割、灾前后图像对齐、损伤等级分类等多个子任务，导致整体方法复杂度较高、实现成本较大。最后，对象级方法对训练数据标注的精度与一致性要求更高，因此标注成本就会更高。与像素级语义标签不同，对象级方法

不仅需要在灾前影像中准确标注每一个目标的实例ID，还需确保灾后影像中的实例与之精确对应。这一过程需要人工进行灾前后图像中的目标匹配、编号一致、区域边界校正等工作，对专业性要求极高。

尽管对象级方法在建模复杂性、性能依赖性等方面存在一定挑战，但其在评估结果的语义一致性与统计可操作性等方面仍展现出明显优势。语义一致性指对象级方法以完整对象为单位进行评估，统计可操作性指输出结果以对象为单位，可直接用于后续的数量统计、空间分布分析等工作。因此，该方向仍具有广阔的发展潜力，值得进一步深入研究与探索。

总体而言，基于双时相变化检测的灾害评估方法能够充分利用灾前/灾后对比信息，对“未损伤—损伤”的突变过程具有较高敏感性，是当前遥感灾害评估中应用最广泛的技术路线。然而，该方法在复杂场景下仍存在显著局限：首先，时间维度的稀疏性使其仅能捕捉受灾前后的“离散快照”，难以还原洪水蔓延或次生灾害等动态演进过程；其

次,对“伪变化”抵抗力较弱,模型极易受到季节植被更替、光照偏差及传感器视角差异的干扰,产生高虚警率。为克服上述瓶颈,研究者开始引入时间序列更长、观测频率更高的多时相数据。通过对多时相序列进行建模来实现对灾害过程的精准回溯。

3.2 基于多时相序列建模的灾害评估方法

基于多时相序列建模的灾害评估方法是指利用多于两个时间点获取的遥感影像序列,对目标区域进行连续监测和分析,通过时间序列数据建模来捕捉动态变化过程。相比于双时相,多时相引入多帧时间信息,能更好地分辨渐变损伤、突变损伤或伪损伤。特别适合地区冲突等人为灾害背景下动态跟踪目标的损伤过程,更真实反映人为灾害对基础设施的破坏链条。

Hannes Mueller等人^[47]利用高分辨率多时相卫星图像来探测城市损坏,采用“CNN+随机森林”的两阶段框架对城市建筑损伤进行高精度跟踪。第一阶段使用CNN网络对单时相图像块进行初步损伤分类;第二阶段引入随机森林,利用时空平滑来优化分类结果,其中空间平滑考虑到损伤的空间聚集性(邻近区域的预测结果),时间平滑利用了多时相影像的时序相关性(前后时间点的预测结果),这一过程利用了损伤“不可逆”的时间先验信息。实验证明,该方法通过考虑时间连续性降低了单时刻预测的假阳性概率,从而提升了灾害评估的精度和可靠性。Hou等人^[20]提出了一种像素级Transformer网络和时态知识引导相结合的建筑模型架构,该方法把每张灾后图像与灾前图像分别组合成双时相图像块,按时间顺序构建多时相序列,然后利用时态卷积解码器提取时序上下文特征,同时引入时间总变分正则项充分利用地区冲突过程中建筑受损不可逆的时序先验。多时相序列的引入显著增强了模型对损伤持续性变化的理解能力,从而提升了在时变复杂场景下的检测精度和稳健性。

基于多时相的遥感时序建模在灾害评估任务中具有明显优势,但也面临诸多挑战。多时相图像通常由不同角度的传感器于不同时间拍摄,存在图像配准误差,即使采用正射校正,微小几何偏移也会导致模型对损伤的误判,尤其在变化幅度较小或边界模糊的情况下更易产生误判。此外,多时相模型需并行处理多个时间帧,计算成本远高于双时相模型,给突发事件快速响应等实时应用带来了较大的部署难度。

3.3 基于多模态遥感数据融合的灾害评估方法

多模态损伤估计是一种结合多源遥感信息(如

光学影像、SAR影像、热红外、LiDAR等)对灾后建筑物或区域进行损伤识别与分级的方法。相较于单一模态,多模态方法通过整合来自多个传感器的互补信息,构建出更完整可靠的目标区域表征,提供更精细的特征集合,从而提高模型的鲁棒性和灾害评估的准确率。

在多模态遥感建筑灾害评估任务中,融合策略主要可分为2类:数据级融合和特征级融合^[48,49],如图6所示。(1)数据级融合方法在输入层对多模态数据进行整合,先将各模态特征合并形成统一的输入表示,再由深度学习模型进行统一处理。这种方式可以在模型初期阶段捕捉跨模态的关联信息,缺点在于其难以应对异构数据(如光学与SAR)在成像机制上的本质差异。由于缺乏对模态特性的针对性建模,简单叠加往往会引入严重的语义噪声,且由于未能有效激活模态间的互补一致性,导致模型极易受无关特征干扰,进而影响最终评估性能。(2)相比之下,特征级融合更为主流,它是指首先对各模态数据进行独立编码来提取各自的特征,然后在中间特征层进行融合,常通过拼接、加权、注意力机制或跨模态交互模块等方式实现深层信息整合,融合后的多模态特征再被送入解码器完成定位和损伤等级分类任务。特征级融合之所以成为当前多模态遥感损伤估计中的主流方法,是因为它充分利用了深度学习的端到端特征建模能力,使不同模态数据在抽象语义层面实现有效互补,从而实现更高的评估精度。

基于数据级融合的多模态灾害评估算法例如M-UNet^[50],在UNet架构中引入多尺度卷积模块,以增强对来自多种传感器的异构图像中的变化检测能力。在基于特征级融合的多模态灾害评估算法方面,Adriano等人^[51]提出了一种基于CNN的深度学习框架,用于从高分辨率光学与SAR数据中融合特征来完成灾害下建筑损伤评估任务。该研究首先构建了一个多模态双时相的建筑损伤数据集,涵盖地震、海啸和台风三种类型的灾害,并设计了五种典型的数据模态组合方案(包含单模态和多模态组合)。在融合策略上,面对多模态输入,模型先分别对不同模态的图像进行特征提取,再在特征层进行融合处理。实验结果表明,多模态融合相比于单一模态输入具有显著性能提升。M3ICNet^[3]是一个能同时处理双时相多模态(光学和SAR)、多分辨率、多层次特征融合的深度神经网络。网络的输入由三个通道组成:低分辨率SAR、中分辨率光学图像、高分辨率光学图像,每个输入路径有独立的编码器,跨模态特征在中间层和高层通过注意力机制




图 6 多模态灾害评估方法

进行融合, 解码部分采用“多路径并行解码+上采样+激活”策略, 结合多尺度监督机制, 实现从融合特征图到建筑损伤像素级预测的高效转换。该研究通过消融实验证明了多模态输入在保持图像语义多样性、提升像素级判别能力方面具有明显优势。

然而, 多模态灾害评估仍面临诸多挑战。首先, 不同模态之间在成像机制、空间分辨率和光谱响应上的本质差异导致特征分布存在较大差异, 增加了模态间对齐与融合的难度。此外, 多模态网络结构通常更为复杂, 融合机制设计和计算资源开销也是部署过程中的关键瓶颈, 尤其是在战区或突发灾害等对响应时效要求极高的应用场景中。

3.4 数据受限下的鲁棒灾害评估方法

结合遥感技术, 深度学习已在灾害损伤的快速评估中展现出显著潜力, 逐渐成为提升应急响应效率的重要手段。当前多数方法依赖灾前与灾后遥感影像的联合训练, 以增强对损伤区域的判别能力。然而, 灾后响应通常具有“小时级”时效要求, 而遥感数据的获取和处理往往存在不可忽视的时间延迟, 尤其在重大突发事件发生后的初始阶段, 受灾区域的高质量遥感影像难以及时获取, 进一步限制了模型的快速部署与实用性。此外, 不同类型的灾害在遥感图像中的表现特征差异显著, 且地理区域间的地物结构、成像条件存在高度异质性, 造成现有模型在跨灾种、跨区域场景中的泛化能力不足, 难以直接推广应用于复杂的现实环境中。

为应对这一挑战, 近年来越来越多研究开始探索如何在数据稀缺的条件下实现有效建模。特别地, 基于伪标签的半监督和无监督学习、迁移学习等技术逐渐成为研究热点。这些方法利用少量标注

或无标注数据完成模型自训练, 或者借助已有源域数据进行迁移学习, 提升模型的泛化能力与适应性, 为实现快速部署、低资源成本的灾害评估系统提供了新的思路和技术支撑。

具体来说, 基于伪标签生成的半监督学习方法利用模型对未标注数据的预测结果(伪标签)作为监督信号, 迭代优化模型, 该方法在典型小样本场景中表现出显著优势。Li等人^[52]通过训练多个建筑提取模型对灾前图像生成伪标签, 并在建筑引导下为双时相影像生成低不确定性的损伤伪标签, 从而在数据有限的情况下提升建筑损伤识别精度。Zhao等人^[53]利用边界检测与像素分割提取结构边界, 融合历史标签与双模型预测结果生成伪标签, 并结合重心相似度设计自适应损失函数, 从而缓解数据标注不足下的精准监测难题。更进一步地, 基于伪标签的无监督学习完全不依赖任何标注数据, 仅通过数据内在规律学习特征。U-BDD++^[54]不依赖任何人工标注数据, 而是利用预训练基础模型(Grounding DINO、SAM、CLIP)在卫星图像上生成伪标签, 这些伪标签再用于微调模型自身, 从而有效解决了灾后标注成本高的问题。

除此之外, 文献^[36,52]利用已有数据通过迁移学习、跨域泛化等技术, 提升了模型在新灾害场景或未见区域的准确性和鲁棒性, 并在一定程度上缓解了灾后标注样本不足问题, 提升了模型跨区域适应能力和部署效率。但该类方法仍存在不足: 在无标签或少标签条件下, 细粒度损伤等级区分仍较困难; 当源域与目标域差异较大时, 还可能出现迁移性能下降甚至负迁移。

总体而言, 上述4类基于深度学习的遥感影像

高价值目标灾害评估技术各有侧重，分别适用于变化检测、时序建模、多模态融合和样本稀缺等场景，其技术特点及优缺点对比如表5所示。进一步地，本文基于公开实验结果对代表性方法的评价指标进行了对比，性能汇总见表6。由于不同方法在

网络结构和任务建模上存在差异，表中结果主要用于反映各技术路线的整体性能水平。

综合表5与表6，可以看到各技术路线的定位精度普遍显著高于损伤分类精度。定量数据表明，模型识别“地物”的能力远强于判断“损伤程度”，

表 5 基于深度学习的遥感影像高价值目标灾害评估技术对比

评估方法	类别	方法描述	典型方法	优点	缺点
基于双时相变化检测的灾害评估方法	密集预测	以每个像素为预测单元输出定位结果和损伤等级	Siam-Unet ^[30] BAT ^[31] SLgViT ^[32] MDA-CD ^[33] ChangeMamba ^[35]	①适合对损伤进行精细评估 ②模型结构简单	①缺乏地物拓扑约束，易产生“椒盐噪声” ②大图处理计算冗余高，依赖后处理
	对象预测	第一阶段生成对象，第二阶段以对象为单位判断其是否损伤和损伤等级	OCD-BDA ^[41] DCA-Det ^[42] OoCDNet ^[43]	①具有目标语义一致性 ②评估结果统计友好，可解释性强	①性能高度依赖第一阶段对象提取准确性 ②方法复杂度较高 ③标注需要更多人工成本
基于多时相序列建模的灾害评估方法	--	通过时间序列数据建模来捕捉损伤动态变化过程	CNN-STs ^[47] TKDS-PtNet ^[20]	①损伤动态变化捕捉能力更强 ②降低模型在单一时间点的假阳性概率，提高评估精度	①多时相图像间存在配准误差 ②多时相计算复杂度高，训练成本高
基于多模态遥感数据的灾害评估方法	数据级融合	在输入层对多模态数据进行整合	M-UNet ^[50]	①结构简单 ②保留了原始数据全部信息	①难以充分挖掘各模态间的深层关联 ②难以针对不同模态进行专门的特征提取和建模
	特征级融合	首先对各模态数据进行独立编码来提取各自特征，然后在中间特征层进行融合	Attention U-Net ^[51] M3ICNet ^[3]	①可设计独立编码器提取各模态特征，灵活性高 ②在语义层面对特征进行融合，能捕获跨模态语义关联	①模态间特征对齐难度大 ②需要更多计算资源和训练时间
数据受限下的鲁棒灾害评估方法	--	利用少量标注或无标注数据完成模型自训练，或者通过借助已有源域数据进行迁移学习	BGPLF ^[52] GEM ^[53] U-BDD++ ^[54] STCA ^[4] TDA-Net ^[55]	①缓解标签数据匮乏问题 ②提升模型的泛化能力 ③加快模型部署速度	①难以保证模型细粒度识别能力 ②域间差异大时效果下降

表 6 基于深度学习的遥感影像高价值目标灾害评估算法性能对比

评估方法	类别	典型方法	数据集	F_1^{overall}	F_1^{loc}	F_1^{dam}
基于双时相变化检测的灾害评估方法	密集预测	Siam-Unet ^[30]	xBD	71.7	85.9	65.6
		BAT ^[31]	xBD	81.3	88.2	78.4
		SLgViT ^[32]	Haidi/Changing	90.4/88.6	-	-
		MDA-CD ^[33]	xBD	76.4	86.2	72.1
		ChangeMamba ^[35]	xBD	81.5	87.4	78.9
	对象预测	OCD-BDA ^[41]	Turkish earthquake dataset	93.0 (OA)	-	-
		DCA-Det ^[42]	AICD-2012	79.8	-	-
		OoCDNet ^[43]	xBD	71.7	-	-
基于多时相序列建模的灾害评估方法	--	CNN-STs ^[47]	WCP	28.3	-	-
		TKDS-PtNet ^[20]	WCP	83.5	-	-
基于多模态遥感数据的灾害评估方法	数据级融合	M-UNet ^[50]	Shuguang dataset	84.7	-	-
	特征级融合	Attention U-Net ^[51]	xBD	50.1	-	-
		M3ICNet ^[3]	WBD/EBD	79.3/75.8	-	-
数据受限下的鲁棒灾害评估方法	--	BGPLF ^[52]	Bright	74.4(mIoU)	-	-
		GEM ^[53]	HC2012	64.5	-	-
		U-BDD++ ^[54]	xBD	-	58.2	63.8
		STCA ^[4]	xBD	47.6	85.0	31.5
		TDA-Net ^[55]	xBD	77.8	-	-

注： F_1^{overall} 表示目标定位分数 F_1^{loc} 和损伤等级分类分数 F_1^{dam} 的加权求和。仅报告 F_1^{overall} 指标的方法表示其指标计算基于定位与分类均正确的目标。个别方法未采用F1，而使用 mIoU 或 OA 进行评价，已在表中以括号形式标注。在数据受限下的鲁棒评估方法中，仍有部分研究采用xBD数据集，这是因为他们引入了无监督或少样本学习策略，以模拟数据受限条件下的应用场景。

例如ChangeMamba定位精度比损伤分级精度高8.5%，这是由于损伤等级判别不仅需要识别外观变化，还需要进一步区分变化“属于何种损伤程度”，这往往涉及材质差异、结构完整性、遮挡因素以及灾害类型差异等复杂语义信息，甚至隐含一定的物理机理与功能影响推理，任务难度显著高于定位。此外，针对同一数据集xBD，数据受限下的方法的整体性能通常低于基于双时相变化检测的灾害评估方法。这主要是因为数据受限方法需要在有限样本条件下同时学习目标外观、变化模式及损伤语义，其特征表达和模型泛化能力更易受到样本不足、类别不均衡及场景多样性的影响，从而在复杂灾害场景中表现出相对较低的评估精度。

同时，模型性能还受到多种关键因素的共同影响。一方面，遥感影像的空间分辨率、成像角度及灾前灾后影像的配准精度会直接影响变化特征的可分性，从而制约损伤判别效果；另一方面，不同灾害类型在损伤机理和外观表现上的差异显著，使得统一模型在跨灾害场景下的泛化能力受到挑战。此外，标注标准的一致性与损伤等级边界的模糊性也会引入不可忽略的标注噪声，进一步放大损伤分类任务的不确定性。

4 发展趋势与挑战

随着遥感观测能力和智能识别算法的持续进步，遥感灾害评估在人为及自然灾害应急响应、城市安全管控等任务中展现出广泛的应用潜力。然而，由于目标形态复杂、场景语义丰富、评估需求精细，当前研究仍面临诸多挑战。基于现有研究成果和应用实践，未来遥感灾害评估的几个关键发展趋势可归纳如下：

4.1 多类型、复杂目标体系的协同评估

当前的灾害评估研究主要聚焦于静态建筑物，然而在实际应用中，如机场、港口、工业园区等复杂基础设施区域，不仅包含建筑结构，还涉及大量可移动目标(如车辆、船舶、飞机)及多个功能子单元(如跑道、机库、燃料储罐、输电站)，损伤表现高度异构，区域内部结构复杂。这类“复杂目标”评估任务要求模型具备跨尺度、多目标、多语义协同推理能力。未来研究应引入层次化表达机制与建模方法，对区域中子目标间的空间关系与功能依赖进行联合建模，提升对多类型、复杂目标的损伤理解能力。

4.2 融合物理机制与功能判别的细粒度灾害评估

在真实灾害场景中，灾害评估不仅需要损伤等级进行分类，更需进一步实现对损伤类型(如穿孔、炸裂、烧蚀、坍塌等)及功能影响评估(如关键

系统是否瘫痪)的细粒度识别。传统数据驱动方法在处理复杂目标结构、多样损伤模式及跨场景泛化时存在准确性与解释性不足的问题。为突破这一瓶颈，未来研究应引入物理机制与功能判别联合驱动的建模范式，融合结构力学、弹道传播、材料退化等物理过程模型，与遥感图像的多源观测数据协同建模。同时结合专家知识和先验规则，实现对目标“强度—结构—功能”的系统表征与推理，构建具备高可信性、强解释性与跨场景适应能力的细粒度灾害评估机制。

4.3 支持终端部署、敏捷推理的灾害评估

灾害评估在灾害应急反馈中对响应时效性有极高要求，而当前深度模型体积大、推理延迟高，难以适配边缘计算场景。未来评估系统应结合模型压缩、结构剪枝与神经架构搜索等技术，构建可嵌入无人机、星载平台等移动设备的轻量评估模型，实现任务驱动、快速部署与即时报送的评估能力。

4.4 标准化、体系化的灾害评估准则构建

当前遥感灾害评估多依赖自定义的判别规则与阈值设定，缺乏统一的、具备物理基础与功能导向的评估准则，导致不同方法和任务间结果可比性差、工程应用困难。同时，现有评价体系普遍缺乏特定于灾害场景的评价指标，难以准确评估模型在真实灾害场景中的实用价值。未来研究亟需推动评估准则的标准化与规范化，结合物理机理建模与目标功能影响分析，建立覆盖多类型目标的损伤等级定义、判别流程与评价标准。同时应进一步丰富评估指标体系，引入结构强度变化、系统功能丧失概率等维度，提高评估结果的通用性、可信度与跨场景适配能力，为灾害响应与决策支持提供更统一、科学的评估依据。

参 考 文 献

- [1] 翁星星, 庞超, 许博文, 等. 面向遥感图像解译的增量深度学习[J]. 电子与信息学报, 2024, 46(10): 3979–4001. doi: [10.11999/JEIT240172](https://doi.org/10.11999/JEIT240172).
WENG Xingxing, PANG Chao, XU Bowen, et al. Incremental deep learning for remote sensing image interpretation[J]. *Journal of Electronics & Information Technology*, 2024, 46(10): 3979–4001. doi: [10.11999/JEIT240172](https://doi.org/10.11999/JEIT240172).
- [2] 程攀, 王光兴, 韩军伟. 深度学习遥感变化检测综述: 典型算法及发展趋势[J]. 遥感学报, 2025, 29(6): 1587–1597. doi: [10.11834/jrs.20254441](https://doi.org/10.11834/jrs.20254441).
CHENG Gong, WANG Guangxing, and HAN Junwei. Deep learning for change detection in remote sensing: A review and new outlooks[J]. *National Remote Sensing Bulletin*, 2025, 29(6): 1587–1597. doi: [10.11834/jrs.20254441](https://doi.org/10.11834/jrs.20254441).

- [3] ZHANG Haiming, MA Guorui, WANG Di, *et al.* M3ICNet: A cross-modal resolution preserving building damage detection method with optical and SAR remote sensing imagery and two heterogeneous image disaster datasets[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2025, 221: 224–250. doi: [10.1016/j.isprsjprs.2025.02.004](https://doi.org/10.1016/j.isprsjprs.2025.02.004).
- [4] ZHENG Zhuo, ZHONG Yanfei, ZHANG Liangpei, *et al.* Towards transferable building damage assessment via unsupervised single-temporal change adaptation[J]. *Remote Sensing of Environment*, 2024, 315: 114416. doi: [10.1016/j.rse.2024.114416](https://doi.org/10.1016/j.rse.2024.114416).
- [5] 刘思琪, 高智, 陈泊安, 等. 基于图网络的遥感地物关系表达与推理的地表异常检测[J]. 电子与信息学报, 2025, 47(6): 1690–1703. doi: [10.11999/JEIT240883](https://doi.org/10.11999/JEIT240883).
LIU Siqi, GAO Zhi, CHEN Boan, *et al.* Earth surface anomaly detection using graph neural network-based representation and reasoning of remote sensing geographic object relationships[J]. *Journal of Electronics & Information Technology*, 2025, 47(6): 1690–1703. doi: [10.11999/JEIT240883](https://doi.org/10.11999/JEIT240883).
- [6] CHEN Guan, LIU Yong, MA Zhangfeng, *et al.* Assessing extent of building damage following an earthquake: Case study of the 2023 Turkey-Syria doublet[J]. *npj Natural Hazards*, 2025, 2(1): 51. doi: [10.1038/s44304-025-00101-7](https://doi.org/10.1038/s44304-025-00101-7).
- [7] 陈昊, 周光尧, 王乾通, 等. 基于一致性生成对抗的遥感多时相建筑物变化检测数据对生成技术[J]. 电子与信息学报, 2025, 47(3): 825–838. doi: [10.11999/JEIT240720](https://doi.org/10.11999/JEIT240720).
CHEN Hao, ZHOU Guangyao, WANG Qiantong, *et al.* Building change detection data generation technology for multi-temporal remote sensing imagery based on consistent generative adversarial[J]. *Journal of Electronics & Information Technology*, 2025, 47(3): 825–838. doi: [10.11999/JEIT240720](https://doi.org/10.11999/JEIT240720).
- [8] GUPTA R, GOODMAN B, PATEL N, *et al.* Creating xBD: A dataset for assessing building damage from satellite imagery[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Long Beach, USA, 2019: 10–17. (查阅网上资料, 未找到本条文献信息, 请确认).
- [9] UNOSAT and United Nations Institute for Training and Research (UNITAR). UNOSAT official website[OL]. <https://www.unitar.org/unosat>, 2025. (查阅网上资料, 链接与内容不符).
- [10] Federal Emergency Management Agency. Damage assessment operations manual: A guide to assessing damage and impact[R]. , 2016. (查阅网上资料, 未找到本条文献报告编号信息, 请确认).
- [11] Federal Emergency Management Agency. Hazus hurricane model user guidance[R]. , 2018. (查阅网上资料, 未找到本条文献报告编号信息, 请确认).
- [12] GRÜNTAL G, MUSSON R, SCHWARZ J, *et al.* EMS-98 (European Macroseismic Scale)[R]. Report of European Seismological Commission, Strasbourg: ESC, 1998. (查阅网上资料, 未找到本条文献信息, 请确认).
- [13] IWG-SEM. Satellite-based emergency mapping – guidelines for building damage assessment[R]. Version 1.0. Geneva: IWG-SEM, 2017. (查阅网上资料, 未找到本条文献信息, 请确认).
- [14] ZHAO Zongze, WANG Fenglei, CHEN Shiyu, *et al.* Deep object segmentation and classification networks for building damage detection using the xBD dataset[J]. *International Journal of Digital Earth*, 2024, 17(1): 2302577. doi: [10.1080/17538947.2024.2302577](https://doi.org/10.1080/17538947.2024.2302577).
- [15] BRAIK A M and KOLIOU M. Automated building damage assessment and large-scale mapping by integrating satellite imagery, GIS, and deep learning[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2024, 39(15): 2389–2404. doi: [10.1111/mice.13197](https://doi.org/10.1111/mice.13197).
- [16] LEE C C, KAUR N, MAHDAVI-AMIRI A, *et al.* Ida-BD: Pre- and post-disaster high-resolution satellite imagery for building damage assessment from hurricane Ida[J/OL]. <https://www.designsafe-ci.org/data/browser/public/designsafe.storage.published/PRJ-3563>, 2022.
- [17] RAHNEMOONFAR M, CHOWDHURY T, and MURPHY R. RescueNet: A high resolution UAV semantic segmentation dataset for natural disaster damage assessment[J]. *Scientific Data*, 2023, 10(1): 913. doi: [10.1038/s41597-023-02799-4](https://doi.org/10.1038/s41597-023-02799-4).
- [18] SUN Yao, WANG Yi, and EINEDER M. Post-earthquake SAR-optical dataset for quick damaged-building detection[C]. IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 3787–3790. doi: [10.1109/IGARSS53475.2024.10641601](https://doi.org/10.1109/IGARSS53475.2024.10641601).
- [19] CHEN Hongruixuan, SONG Jian, DIETRICH O, *et al.* Bright: A globally distributed multimodal building damage assessment dataset with very-high-resolution for all-weather disaster response[J]. *Earth System Science Data*, 2025, 17(11): 6217–6253. doi: [10.5194/essd-17-6217-2025](https://doi.org/10.5194/essd-17-6217-2025).
- [20] HOU Zhengyang, QU Ying ZHANG Liqiang, *et al.* War city profiles drawn from satellite images[J]. *Nature Cities*, 2024, 1(5): 359–369. doi: [10.1038/s44284-024-00060-6](https://doi.org/10.1038/s44284-024-00060-6).
- [21] JIANG Wandong, SUN Yuli, LEI Lin, *et al.* Change detection of multisource remote sensing images: A review[J]. *International Journal of Digital Earth*, 2024, 17(1): 2398051. doi: [10.1080/17538947.2024.2398051](https://doi.org/10.1080/17538947.2024.2398051).
- [22] WANG Lukang, ZHANG Min, GAO Xu, *et al.* Advances and challenges in deep learning-based change detection for remote sensing images: A review through various learning paradigms[J]. *Remote Sensing*, 2024, 16(5): 804. doi: [10.3390/rs16050804](https://doi.org/10.3390/rs16050804).
- [23] GU Jiancheng, XIE Zhengtao, ZHANG Jiandong, *et al.*

- Advances in rapid damage identification methods for post-disaster regional buildings based on remote sensing images: A survey[J]. *Buildings*, 2024, 14(4): 898. doi: [10.3390/buildings14040898](#).
- [24] WANG Lili, WU Jidong, YANG Youtian, *et al.* Deep learning models for hazard-damaged building detection using remote sensing datasets: A comprehensive review[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 15301–15318. doi: [10.1109/JSTARS.2024.3449097](#).
- [25] MOYA L, GEIß C, HASHIMOTO M, *et al.* Disaster intensity-based selection of training samples for remote sensing building damage classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(10): 8288–8304. doi: [10.1109/TGRS.2020.3046004](#).
- [26] BALLINGER O. Open access battle damage detection via pixel-wise T-test on sentinel-1 imagery[J]. *Remote Sensing of Environment*, 2025, 331: 115025. doi: [10.1016/j.rse.2025.115025](#).
- [27] DIETRICH O, PETERS T, GARNOT V S F, *et al.* An open-source tool for mapping war destruction at scale in Ukraine using sentinel-1 time series[J]. *Communications Earth & Environment*, 2025, 6(1): 215. doi: [10.1038/s43247-025-02183-7](#).
- [28] BRAIK A M, HAN Xu, and KOLIOU M. A framework for resilience analysis and equitable recovery in tornado-impacted communities using agent-based modeling and computer vision-based damage assessment[J]. *International Journal of Disaster Risk Reduction*, 2025, 121: 105427. doi: [10.1016/j.ijdrr.2025.105427](#).
- [29] WANG Yu, LI Yue, and ZHANG Shufeng. Automatic detection of war-destroyed buildings from high-resolution remote sensing images[J]. *Remote Sensing*, 2025, 17(3): 509. doi: [10.3390/rs17030509](#).
- [30] DUNNHOFER M, ANTICO M, SASAZAWA F, *et al.* Siam-U-Net: Encoder-decoder Siamese network for knee cartilage tracking in ultrasound images[J]. *Medical Image Analysis*, 2020, 60: 101631. doi: [10.1016/j.media.2019.101631](#).
- [31] LU Wen, WEI Lu, and NGUYEN M. Bitemporal attention transformer for building change detection and building damage assessment[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 4917–4935. doi: [10.1109/JSTARS.2024.3354310](#).
- [32] QIAO Wenfan, SHEN Li, WANG Wei, *et al.* A weakly supervised bitemporal scene change detection approach for pixel-level building damage assessment using pre- and post-disaster high-resolution remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5648523. doi: [10.1109/TGRS.2024.3494257](#).
- [33] HAN Dongzhe, YANG Guang, LU Wangze, *et al.* A multi-level damage assessment model based on change detection technology in remote sensing images[J]. *Natural Hazards*, 2025, 121(6): 7367–7388. doi: [10.1007/s11069-024-07094-y](#).
- [34] GU A and DAO T. Mamba: Linear-time sequence modeling with selective state spaces[C]. First Conference on Language Modeling, Philadelphia, USA, 2024.
- [35] CHEN Hongruixuan, SONG Jian, HAN Chengxi, *et al.* ChangeMamba: Remote sensing change detection with spatiotemporal state space model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4409720. doi: [10.1109/TGRS.2024.3417253](#).
- [36] WIGUNA S, ADRIANO B, MAS E, *et al.* Evaluation of deep learning models for building damage mapping in emergency response settings[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 5651–5667. doi: [10.1109/JSTARS.2024.3367853](#).
- [37] REN Shaoqing, HE Kaiming, GIRSHICK R, *et al.* Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137–1149. doi: [10.1109/TPAMI.2016.2577031](#).
- [38] WANG Ao, CHEN Hui, LIU Lihao, *et al.* YOLOv10: Real-time end-to-end object detection[C]. Proceedings of the 38th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2024: 3429.
- [39] HE Kaiming, GKIOXARI G, DOLLÁR P, *et al.* Mask R-CNN[C]. Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017: 2980–2988. doi: [10.1109/ICCV.2017.322](#).
- [40] CHENG Bowen, MISRA I, SCHWING A G, *et al.* Masked-attention mask transformer for universal image segmentation[C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, USA, 2022: 1280–1289. doi: [10.1109/CVPR52688.2022.00135](#).
- [41] XIE Zhengtao, ZHOU Zifan, HE Xinhao, *et al.* Methodology for object-level change detection in post-earthquake building damage assessment based on remote sensing images: OCD-BDA[J]. *Remote Sensing*, 2024, 16(22): 4263. doi: [10.3390/rs16224263](#).
- [42] ZHANG Lin, HU Xiangyun, ZHANG Mi, *et al.* Object-level change detection with a dual correlation attention-guided detector[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 177: 147–160. doi: [10.1016/j.isprsjprs.2021.05.002](#).
- [43] ZHANG Haiming, ZHANG Yongxian, WANG Di, *et al.* Damaged building object detection from bitemporal remote sensing imagery: A cross-task integration network and five datasets[J]. *IEEE Transactions on Geoscience and Remote*

- Sensing*, 2024, 62: 5648827. doi: [10.1109/TGRS.2024.3493886](https://doi.org/10.1109/TGRS.2024.3493886).
- [44] ZHENG Zhuo, ZHONG Yanfei, WANG Junjue, *et al.* Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters[J]. *Remote Sensing of Environment*, 2021, 265: 112636. doi: [10.1016/j.rse.2021.112636](https://doi.org/10.1016/j.rse.2021.112636).
- [45] ZHANG Hongyan, LIN Manhui, YANG Guangyi, *et al.* ESCNet: An end-to-end superpixel-enhanced change detection network for very-high-resolution remote sensing images[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(1): 28–42. doi: [10.1109/TNNLS.2021.3089332](https://doi.org/10.1109/TNNLS.2021.3089332).
- [46] ZHAN Tao, GONG Maoguo, JIANG Xiangming, *et al.* S³Net: Superpixel-guided self-supervised learning network for multitemporal image change detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 5002205. doi: [10.1109/LGRS.2023.3300308](https://doi.org/10.1109/LGRS.2023.3300308).
- [47] MUELLER H, GROEGER A, HERSH J, *et al.* Monitoring war destruction from space using machine learning[J]. *Proceedings of the National Academy of Sciences*, 2021, 118(23): e2025400118. doi: [10.1073/pnas.2025400118](https://doi.org/10.1073/pnas.2025400118).
- [48] LI Jiaxin, HONG Danfeng, GAO Lianru, *et al.* Deep learning in multimodal remote sensing data fusion: A comprehensive review[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 112: 102926. doi: [10.1016/j.jag.2022.102926](https://doi.org/10.1016/j.jag.2022.102926).
- [49] SAIDI S, IDBRAIM S, KARMOUDE Y, *et al.* Deep-learning for change detection using multi-modal fusion of remote sensing images: A review[J]. *Remote Sensing*, 2024, 16(20): 3852. doi: [10.3390/rs16203852](https://doi.org/10.3390/rs16203852).
- [50] LV Zhiyong, HUANG Haitao, GAO Lipeng, *et al.* Simple multiscale UNet for change detection with heterogeneous remote sensing images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 2504905. doi: [10.1109/LGRS.2022.3173300](https://doi.org/10.1109/LGRS.2022.3173300).
- [51] ADRIANO B, YOKOYA N, XIA Junshi, *et al.* Learning from multimodal and multitemporal earth observation data for building damage mapping[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 175: 132–143. doi: [10.1016/j.isprsjprs.2021.02.016](https://doi.org/10.1016/j.isprsjprs.2021.02.016).
- [52] LI Jiepan, HUANG He, SHENG Yu, *et al.* Building-guided pseudo-label learning for cross-modal building damage mapping[C]. IGARSS 2025-2025 IEEE International Geoscience and Remote Sensing Symposium, Brisbane, Australia, 2025: 228–232. doi: [10.1109/IGARSS55030.2025.11243835](https://doi.org/10.1109/IGARSS55030.2025.11243835).
- [53] ZHAO Chunhui, SHEN Yi, SU Nan, *et al.* Gully erosion monitoring based on semi-supervised semantic segmentation with boundary-guided pseudo-label generation strategy and adaptive loss function[J]. *Remote Sensing*, 2022, 14(20): 5110. doi: [10.3390/rs14205110](https://doi.org/10.3390/rs14205110).
- [54] ZHANG Yiyun, WANG Zijian, LUO Yadan, *et al.* Learning efficient unsupervised satellite image-based building damage detection[C]. 2023 IEEE International Conference on Data Mining (ICDM), Shanghai, China, 2023: 1547–1552. doi: [10.1109/ICDM58522.2023.00206](https://doi.org/10.1109/ICDM58522.2023.00206).
- [55] ZHANG Haiming, WANG Mingchang, ZHANG Yongxian, *et al.* TDA-Net: A novel transfer deep attention network for rapid response to building damage discovery[J]. *Remote Sensing*, 2022, 14(15): 3687. doi: [10.3390/rs14153687](https://doi.org/10.3390/rs14153687).
- 张伊丹：女，助理研究员，研究方向为遥感图像智能解译等。
- 冯瑛超：男，助理研究员，研究方向为空天遥感信息处理等。
- 王天琦：女，博士生，研究方向为遥感图像智能解译等。
- 刘煜：女，博士生，研究方向为计算机视觉、遥感多模态目标解译等。
- 王萌雨：女，博士生，研究方向为计算机视觉、遥感语义分割等。
- 侯钟砚：男，博士生，研究方向为遥感图像智能解译等。

A Review of Advances and Challenges in Intelligent Disaster Assessment of High-Value Objects in Remote Sensing Imagery

ZHANG Yidan^{①②③④} FENG Yingchao^{①④} WANG Tianqi^{①②③④} LIU Yu^{①②③④}
WANG Mengyu^{①②③④} HOU Zhongyan^{①②③④}

^①(Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100190, China)

^②(University of Chinese Academy of Sciences, Beijing 100190, China)

^③((School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China)

^④(Key Laboratory of Target Cognition and Application Technology(TCAT), Beijing 100190, China)

Abstract:

Significance The rapid and accurate disaster assessment of objects in the aftermath of disasters is critical for enabling effective emergency response and post-disaster recovery operations. Intelligent remote sensing technologies, empowered by deep learning, provide scalable, objective, and efficient means of assessing disaster across large and complex environments, such as densely populated urban centers, transportation hubs, and critical energy infrastructure. By leveraging high-resolution satellite and aerial imagery, these technologies can provide timely situational awareness for decision-makers, supporting prioritization in rescue and recovery tasks. Despite significant advancements in methods and applications, there remains a lack of comprehensive synthesis in the field, leading to fragmented practices and inconsistent benchmarks across studies. This study addresses this critical gap by providing a structured and systematic review that consolidates technical foundations, commonly used datasets, evaluation metrics, and methodological advances in deep learning-based remote sensing disaster assessment. The overarching goal is to accelerate the adoption and operationalization of these technologies in real-world disaster scenarios, ultimately contributing to the construction of resilient cities and infrastructures under increasing environmental and geopolitical risks.

Progress In recent years, deep learning-based remote sensing disaster assessment methods have developed rapidly, demonstrating notable improvements in classification accuracy, processing automation, and scalability. Significant advances include bi-temporal change detection methods that can precisely localize disaster by capturing differences before and after disaster events, and multi-temporal sequence modeling approaches that extract evolving disaster patterns and degradation trends across time-series data. Furthermore, multi-modal data fusion strategies that combine optical, Synthetic Aperture Radar(SAR), and Light Detection and Ranging (LiDAR) data have enhanced the ability to analyze complex disaster characteristics under varying observation conditions. Advanced techniques to address data scarcity, such as transfer learning and self-supervised learning, have further extended the applicability of disaster assessment methods in data-constrained environments. These advances collectively contribute to improving the responsiveness and effectiveness of disaster assessment systems in supporting emergency decision-making and resource allocation during critical disaster events.

Conclusions This study systematically categorizes and evaluates the technical landscape of deep learning-based remote sensing disaster assessment for objects, highlighting the strengths and limitations of bi-temporal, multi-temporal, multi-modal, and data-scarce scenario methods. While existing approaches demonstrate considerable potential in addressing various challenges in post-disaster assessment, challenges remain in ensuring robustness across diverse environments and operational conditions. The review underscores the need for standardized disaster classification criteria and comprehensive evaluation frameworks that consider both physical disaster and functional impacts to facilitate practical and consistent disaster assessments in real-world deployments.

Prospects Future research in remote sensing-based disaster assessment should focus on developing multi-level collaborative frameworks for evaluating diverse objects across spatial and functional scales, enabling holistic disaster impact assessment that captures both direct and cascading effects. Complex scenarios such as airports, industrial zones, and ports contain static structures, moving objects, and interdependent functional units, thus requiring hierarchical modeling and multi-object reasoning. Physics-driven and hybrid approaches integrating structural mechanics, material degradation, and expert knowledge can further improve interpretability and generalization. Meanwhile, lightweight model design and edge deployment are important for real-time assessment on drones and satellites in emergency situations. Standardized evaluation metrics that combine physical disaster mechanisms with functional impact analysis will also be essential for practical deployment. Together, these directions will help transform intelligent remote sensing technologies into actionable tools for disaster response and recovery.

Key words: Intelligent disaster assessment; Remote sensing image; Deep Learning