

引文格式: 葛小三, 陈曦, 赵文智, 等. 基于生成对抗网络的建筑物损毁检测[J]. 测绘学报, 2022, 51(2): 238-247. DOI: 10.11947/j.AGCS.2022.20200318.

GE Xiaosan, CHEN Xi, ZHAO Wenzhi, et al. Detection of damaged buildings based on generative adversarial networks[J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(2): 238-247. DOI: 10.11947/j.AGCS.2022.20200318.

基于生成对抗网络的建筑物损毁检测

葛小三^{1,2}, 陈曦^{1,2,3}, 赵文智³, 李瑞祥^{1,2}

1. 河南理工大学测绘与国土信息工程学院,河南 焦作 454003; 2. 河南理工大学自然资源部矿山时空信息与生态修复重点实验室,河南 焦作 454003; 3. 北京师范大学地理科学学部遥感科学与工程研究院,北京 100875

Detection of damaged buildings based on generative adversarial networks

GE Xiaosan^{1,2}, CHEN XI^{1,2,3}, ZHAO Wenzhi³, LI Ruixiang^{1,2}

1. School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo 454003, China;
2. Key Laboratory of Spatio-temporal Information and Ecological Restoration of Mines (MNR), Henan Polytechnic University, Jiaozuo 454003, China; 3. Institute of Remote Sensing Science and Engineering, Faculty of Geographical Science, Beijing Normal University, Beijing 100875, China

Abstract: As one of the most affected hazard-affected bodies in natural disasters, accurate damage information extraction of buildings plays a significant role in post-disaster emergency rescue. Referring to the idea of multi-mode fusion technique, a recursive generative adversarial networks (RS-GAN) method is proposed to automatically detect damaged buildings. In RS-GAN, the workflow of damaged buildings detection is composed of two sub-tasks as follows: building identification before disasters as well as damaged building detection after disasters, which are completed in two GAN branches respectively. Specifically, RS-GAN adds a joint loss function to connect the two GAN branches, making full use of the potential mutual benefit between the two tasks to improve the detection accuracy. In addition, the results of building identification are added to the damaged building detection task to locate potential damaged areas. The method proposed in this paper is an end-to-end model, which can automatically detect damaged buildings without excessive manual intervention. To verify the effect of the RS-GAN model, in this paper, two experiments were set with the Santa Rosa dataset and Missouri respectively. Experimental results show that RS-GAN method has better detection performance compared to other competitive methods, and the overall accuracy and average accuracy on the Santa Rosa data set are 0.90 and 0.86, respectively.

Key words: generative adversarial networks; pre-disaster and post-disaster bitemporal images; building contour extraction; damaged building detection; step-by-step learning

Foundation support: Beijing Municipal Natural Science Foundation (No. 4214065); The National Natural Science Foundation of China (No. 41572341); Natural Science Foundation of Henan, China (222300420450); The National Key Research and Development Program of China (No. 2018YFC1508903)

摘要: 建筑物作为自然灾害中最受影响的承灾体之一,其损毁信息的准确提取对灾后应急救援具有十分重要的意义。本文借鉴多模态的思想,提出了一种自动检测损毁建筑物的 recursive-generative adversarial networks(RS-GAN)方法,将损毁建筑物检测分为灾前建筑物识别和灾后损毁建筑物检测两个任务,且分别在两个 GAN 分支中完成。RS-GAN 加入联合损失函数将两个 GAN 分支进行连接,充分利用两个任务之间的潜在互利性提升检测效果。RS-GAN 利用第 1 条 GAN 分支识别建筑物灾前形状与位置,并将识别结果作为第 2 条 GAN 分支的输入进行损毁建筑物检测任务,从而使检测结果具有

更清晰的轮廓。该方法为端到端模型,在不需要过多的人工干预情形下,实现了损毁建筑物的自动检测。为了验证 RS-GAN 模型的效果,在圣罗莎和密苏里两个数据集上进行了测试。试验结果表明,RS-GAN 方法拥有更好的检测性能,在圣罗莎数据集上的总体精度和平均精度分别达到了 0.90 和 0.86。

关键词:生成对抗网络(GAN);灾前灾后双时相遥感影像;建筑物轮廓提取;损毁建筑物检测;分步学习

中图分类号:P237

文献标识码:A

文章编号:1001-1595(2022)02-0238-10

基金项目:北京市自然科学基金(4214065);国家自然科学基金(41572341);河南省自然科学基金项目(222300420450);国家重点研发计划(2018YFC1508903)

近年来,全球气候变化不断加剧、自然灾害日益频发,造成了严重的人员伤亡和经济损失,已成为威胁人类生命安全的重大问题之一^[1]。建筑物作为人们生活的主要场所,是人口和财产的集中地带,快速准确地了解灾后建筑物的损毁信息对于灾后应急决策与恢复重建意义重大^[2]。随着遥感平台和传感器的发展,遥感影像的分辨率逐渐提高,可以从影像中提取更详细的地表覆盖信息,为遥感技术在灾情检测中的应用带来可能。但更详细的信息意味着更加严重的类内差异,再加上大气干扰和光照变化带来的大量伪变化,使得高分辨率影像建筑物变得难以识别。在灾害中破损能够建筑物的光谱和纹理信息更为复杂,因此准确检测损毁建筑物是一个极大的挑战^[3]。

国内外学者针对损毁建筑物检测任务利用多种遥感数据源做了大量工作,高分辨率影像、SAR 影像和激光雷达等数据先后被应用到损毁建筑物检测中。其中,基于高分辨率影像的研究主要集中在损毁特征以及检测方法的选择上^[4]。高分辨率的灾后影像包含丰富的地物细节,如颜色特征^[5]、纹理特征^[6]、高度特征^[7]等。由于倒塌建筑物结构复杂,单一特征往往难以准确描述复杂建筑物目标^[8],而简单的多特征堆叠会带来计算的冗余,因此怎样选择典型特征一直是建筑物损毁研究的难点^[9-11]。SAR 影像能够穿透云雨雾雪,在灾害等恶劣环境下具有天然的优势^[12]。完好建筑物和损毁建筑物在 SAR 影像中主要表现为极化特征与纹理特征的差异,但对数据质量的要求相对较高,且应用端需要相对较高的专业知识水平。激光雷达作为一种主动式观测技术,可提供建筑物较为全面的视角及更多的形态学特征,但观测区域有限,数据难以做到全面覆盖^[13-14]。现阶段,应用高分辨率影像进行灾损检测仍是最好的选择,其中单一地使用灾后影像和使用灾前灾后双时相影像两种方式较为常用。相对于使用灾前灾后双时相遥感影像,单一的灾后

影像获取较为容易,常用于灾后信息快速获取。但单一的灾后影像可提供的信息有限,往往难以获得令人满意的结果^[15]。在灾前灾后影像充足的情况下,使用灾前灾后影像进行变化检测可以获得更好的检测结果^[16]。

在过去的几十年中,新的变化检测方法不断出现。其中,最常见的是机器学习的方法,如支持向量机(SVM)、变化向量分析(CVA)^[17]和主成分分析(PCA)^[18]。然而,在自然灾害发生之后,破损能够建筑物特征呈现出巨大的差异,传统机器学习方法很难区分。深度学习算法的兴起为建筑物损毁信息提取提供了一种新的解决方案。深度学习方法能够通过多层次卷积结构识别影像中语义丰富的高级特征,在损毁检测任务中具有显著优势^[19-22]。文献[23]利用深度卷积神经网络(DCNN)提取深层次影像特征来判断建筑物是否损坏,并证明了 DCNN 提取的高级特征相对于传统特征具有更好的表征能力。文献[24]将卷积自动编码器学习到的知识转移到 CNN 分类器,发现 CNN 分类器可以改善特征的辨识度。文献[25]使用 UNet 进行建筑物屋顶损伤检测,并提出了 4 种策略来缓解样本数量失衡带来的过拟合效应。然而,CNN、UNet 都是判别式网络,需要大量精确的标记样本,在灾害背景下往往很难满足这一要求。

生成对抗模型(GAN)作为一种无或半监督生成网络,其训练过程只需要少量训练样本,因此在遥感目标识别领域中得到广泛应用^[26]。文献[27]利用条件生成对抗网络(CGAN)将光学数据和 SAR 数据融合进行变化监测,有效减小了伪变化的影响。文献[28]使用 pix2pix-GAN 对高分辨率遥感影像进行了变化检测研究,证明了 pix2pix 框架在变化监测中的可用性。文献[29]提出了一种 MeGAN 模型,将季节变化项和度量学习融入 pix2pix 框架用于两个不同季节之间遥感影像的变化监测,该模型有效抑制了季节性差

异产生的伪变化。pix2pix 是一种端到端的框架,不需要特殊的人为设计,通过生成网络和判别网络的相互对抗竞争建立输入图像和输出图像之间的良好映射关系,适合复杂环境下的变化检测任务。然而,pix2pix 的局限性在于通过多层卷积运算提取感兴趣区域,通常会导致计算的冗余,并且很难找到建筑物准确边界。此外,损毁建筑物具有复杂的变化特征,单一的 GAN 结构很难达到理想的效果。

综上所述,损毁建筑物检测的主要困难在于如何准确确定建筑物变化区域轮廓和解决样本不足带来的训练不足或过拟合问题。因此,本文提出了一种基于 pix2pix 框架的 RecurSive-GAN (RS-GAN)方法。该方法学习灾前灾后双时相影像之间的特征差异,实现损毁建筑物自动检测,并输出建筑物受损分布图。本文采用了两个相同的 pix2pix 框架,分别用于建筑物识别和损毁建筑物检测,如图 1 所示。为了解决检测边界模糊问题,将建筑物识别结果与灾前灾后影像输入损毁建筑物检测模块,为其提供潜在区域建议。由于损毁建筑物检测是建立在建筑物识别的结果之上,两者具有很强的相关性,因此加入联合损失函数以提高模型对损毁特征的识别能力。

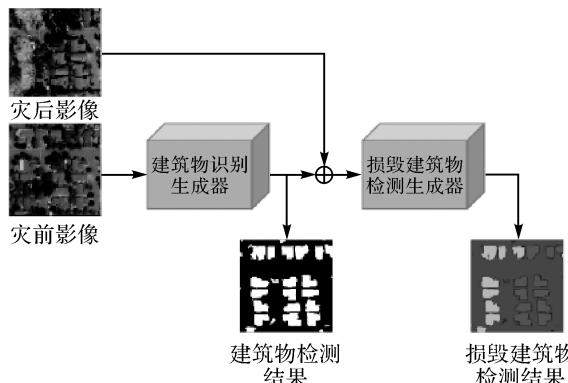


图 1 RS-GAN 工作流程

Fig.1 Procedure of RS-GAN method

1 研究方法

由于建筑物损毁信息提取是一个十分复杂的过程,单一的映射过程难以获得好的效果,因此基于多模态 GAN 的原理,本文提了 recursive-generative adversarial networks(RS-GAN)方法。RS-GAN 基于 pix2pix 框架构建,由两个相似的 pix2pix 模块组成。

1.1 pix2pix 网络模型

pix2pix 算法由一个生成器和一个判别器构成,生成器用来生成模拟样本,使其分布 p_z 尽可能类似于真实样本数据分布 p_d 以欺骗判别器 $D(x)$,判别器尽可能地区分样本来源于生成器还是真实样本,通过两个模块间的对抗过程使模型达到最优。pix2pix 的目标函数可以表示为

$$\min_G \max_D V(D, G) = E_{x \sim p_d} [\log D(x)] + E_{z \sim p_z} [\log(1 - D(x, G(z)))] \quad (1)$$

式中, p_d 表示真实数据 x 的样本分布; z 表示随机噪声; $G(z)$ 表示生成器产生的模拟样本。令 θ_g 和 θ_d 分别代表生成器 G 和鉴别器 D 的参数,在训练的过程中 θ_d 每更新一次, θ_g 也对应更新一次,直到损失函数收敛。本文在表 1 中展示了一个 pix2pix 网络的具体配置,生成器是一个类似于 UNet 的跳网结构,包括 8 个下采样和 8 个上采样步骤,并在最后加入了 tanh 激活函数;判别器采用 8 个下采样。最终输出损毁建筑物分布图。

1.2 Recursive-generative adversarial networks (RS-GAN) 方法

GAN 是一个动态对抗过程,在生成器与判别器的博弈中寻找源域到目标域的最佳映射。建筑物损毁信息提取是一个十分复杂的过程,单一的映射过程难以获得好的效果。建筑物识别任务到损毁建筑物检测任务是一个递进的过程,两者之间有很强的相关性。因此,使用两个 pix2pix 框架将两者联系起来。如图 2 所示,将同一地区建筑物识别生成器模块的输出作为叠加项输入损毁建筑物检测模块中,在训练过程中,为损毁建筑物检测生成器提供潜在区域建议。同时,设计了一个联合损失函数,充分利用两个任务之间的潜在互利性,增强模型的鉴别能力。用 x_p 表示输入灾前影像, y_p 表示建筑物真实地表标签,建筑物识别 pix2pix 的目标函数可以表示为

$$V_1 = \min_G \max_D V(D_1, G_1) = E_{x \sim p_d} [\log D_1(x_p, y_p)] + E_{z \sim p_z} [\log(1 - D_1(x_p, G_1(x_p)))] \quad (2)$$

式中, p_d 表示真实建筑物地面分布(建筑物标签图)的数据分布; p_z 表示输入灾前图像的数据分布。将建筑物识别 pix2pix 的输出表示为 $s = G_1(x_p)$, 灾后建筑物和建筑物损毁真实地表标签分别表示为 x_q, y_q , 那么损毁建筑物检测 pix2pix

的目标函数可以表示为

$$V_2 = \min_G \max_D V(D_2, G_2) =$$

$$E_{x \sim p_t} [\log D_2(s, x_q, y_q)] +$$

$$E_{s \sim p_s} [\log(1 - D_2(s, x_q, G_2(G_1(x_p), x_q)))] \quad (3)$$

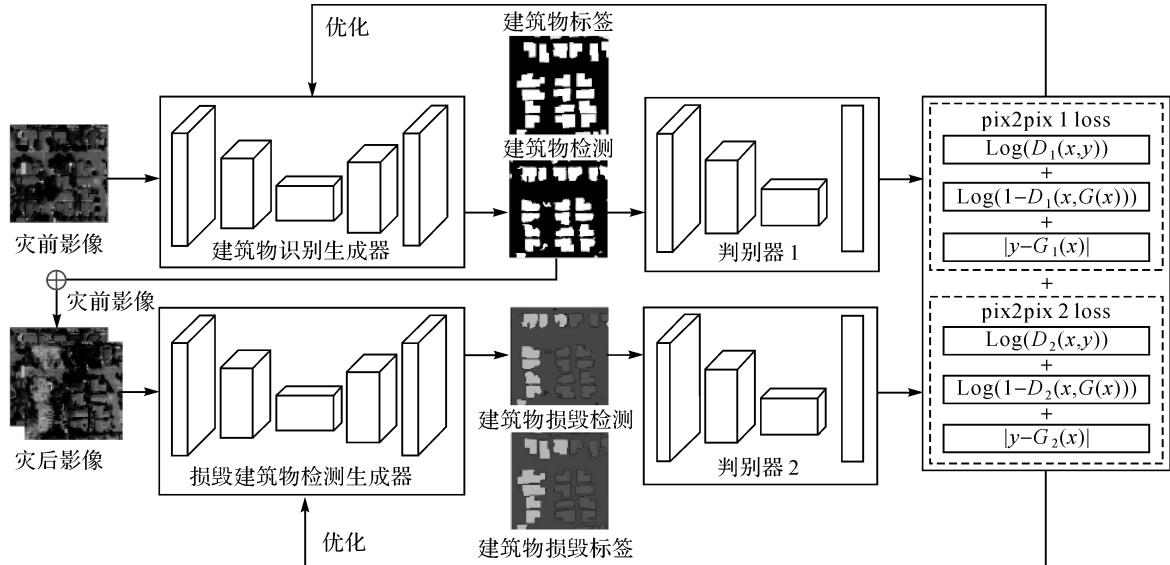


图2 RS-GAN 框架

Fig.2 Architecture diagram of RS-GAN method

表1 pix2pix 详细配置

Tab.1 Detail configuration of pix2pix framework

name	layer	kernel	stride	padding	feature	activation	
G	conv1	4×4	3	1	64	None	
	conv2	4×4	2	1	128	Relu	
	conv3	4×4	2	1	256	Relu	
	conv4-8	4×4	2	1	512	Relu	
	dconv9-12	4×4	2	1	512	Relu	
	dconv13	4×4	2	1	256	Relu	
	dconv14	4×4	2	1	128	Relu	
	dconv15	4×4	2	1	64	Relu	
	dconv16	4×4	2	1	3	tanh	
	conv1	4×4	3	1	64	None	
	conv2	4×4	2	1	128	Relu	
	D	conv3	4×4	2	1	256	Relu
	conv4-7	4×4	2	1	512	Relu	
	conv8	4×4	2	1	1	Relu	

同时,为了使模型更快达到纳什均衡,本文在模型中加入了 L1 损失函数

$$L_{\text{Gan}} = E_{x,y} \|y - G(x)\| \quad (4)$$

那么,最终的联合损失函数可以表示为

$$\min_{G_1, G_2} \max_{D_1, D_2} (G_1, G_2, D_1, D_2) = V_1 + L_{\text{Gan}_1} + c(V_2 + L_{\text{Gan}_2}) \quad (5)$$

式中,c 为平衡建筑物识别和损毁信息提取任务所需的超参数,在本文中设置为 3。在训练过程

中,生成器组和鉴别器组的参数 θ_g, θ_d 是一个交替更新的过程,直到损失函数收敛,RS-GAN 的训练过程如下。

算法 Recursive Generative Adversarial Networks (RS-GAN) 算法,其中 p_z 和 p_s 分别为建筑物真实地表和损毁建筑物真实地表的样本分布。

输入: m 个灾前影像 $\{x_p^1, x_p^2, \dots, x_p^m\}$ 抽样样本 $p_z(x_p)$
 m 个建筑物真实地表标注 $\{y_p^1, y_p^2, \dots, y_p^m\}$ 抽样样本 $p_z(y_p)$
 m 个灾后影像 $\{x_q^1, x_q^2, \dots, x_q^m\}$ 抽样样本 $p_s(x_q)$
 m 个损毁建筑物真实地表标注 $\{y_q^1, y_q^2, \dots, y_q^m\}$ 抽样样本 $p_s(y_q)$

输出:建筑物损毁分布图

for number of training iterations do
Step 1: 更新建筑物检测鉴别器 D_1 的参数

$\nabla_{d_1} \frac{1}{m} \sum_{i=1}^m [\log D_1(x_p^i, y_p^i) + \log(1 - D_1(x_p^i, G_1(x_p^i, y_p^i)))]$

D 输出建筑物分布图 $G_1(x_p^i)$

Step 2: 更新损毁建筑物检测鉴别器 D_2 的参数

$\nabla_{d_2} \frac{1}{m} \sum_{i=1}^m [\log D_2(G_1(x_p^i), x_q^i, y_q^i) + \log(1 - D_2(G_1(x_p^i), x_q^i, G_2(G_1(x_p^i), x_q^i)))]$

输出损毁建筑物分布图 $G_2(G_1(x_p^i), x_q^i)$

Step 3: 更新建筑物检测鉴别器 G_1 的参数

$$G = \nabla_{g_1} \frac{1}{m} \sum_{i=1}^m [\log(1 - D_1(x_p^i, G_1(x_p^i)))]$$

Step 4: 更新损毁建筑物检测鉴别器 G_2 的参数

$$\nabla_{d_2} \frac{1}{m} \sum_{i=1}^m [\log(1 - D_2(G_1(x_p^i), x_q^i, G_2(G_1(x_p^i), x_q^i)))]$$

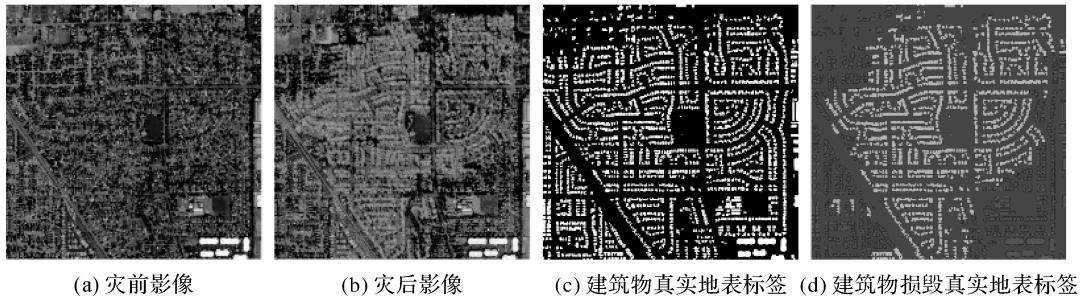
end for

2 试验与分析

2.1 试验数据

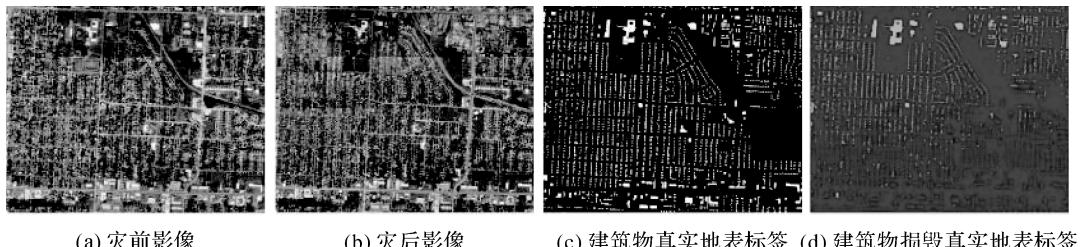
试验数据集分别选用圣罗莎大火(Santa Rosa, 2017, 美国加利福尼亚州)和飓风多里安(Missouri, 2011, 美国密苏里州)两组灾前灾后 worldview 影像, 影像来源于 DigitalGlobe 提供的 XBD 建筑物损毁数据集^[30]。该数据集收集了世界各地 19 个灾害事件(如洪水、地震和飓风)的高

分辨率遥感影像对, 并经过了严格的影像配准。如图 3、图 4 所示, 圣罗莎和密苏里数据集的尺寸分别为 3072×3072 和 5120×4096 , 空间分辨率约为 0.5 m, 包含 RGB 3 个波段。该数据集结合实地调查数据, 参考 HAZUS 自然灾害分析工具^[31]、美国联邦应急管理局(FEMA)损坏评估操作手册、Kelman 所提出的灾损评估标准^[32]和欧洲宏观地震烈度表(EMS-98)^[33]将建筑物损毁分为 4 级。由于卫星视角所带来的局限性, 大多数情况下只能看到建筑物的顶面, 传统的基于物理结构或功能的建筑物损毁评价标准在此情况下难以适用。因此基于此数据集所提出的建筑物损毁评价, 将建筑物分为完好或轻度损毁(完好)和中度损毁或倒塌(损毁)两级目标, 如图 5 所示。



(a) 灾前影像 (b) 灾后影像 (c) 建筑物真实地表标签 (d) 建筑物损毁真实地表标签

图 3 圣罗莎大火数据集
Fig.3 Santa Rosa data sets



(a) 灾前影像 (b) 灾后影像 (c) 建筑物真实地表标签 (d) 建筑物损毁真实地表标签

图 4 密苏里龙卷风数据集
Fig.4 Missouri tornado data sets

在本文试验中, 数据集的 30% 作为训练集, 其余的 70% 作为测试集。为了避免训练样本与测试样本之间可能存在的相关性, 训练集和测试集被分成两个独立的区域。本文将数据集裁剪为 256×256 的小块, 为了扩充训练样本, 本文随机不重复抽取样本点, 并以样本点为中心切割影像块; 测试集以相邻影像块中心点距离为 256 作无重叠切割。为了验证所提出方法的性能, 分别使用了 RandomForest(RF), UNet 和 pix2pix 作为

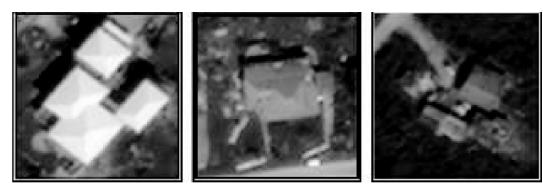
比较算法。比较算法中 pix2pix 算法与本文算法采用相同的结构。为了定量说明模型的准确性, 选择精度(precision), 召回率(recall), 总体精度(overall accuracy), 平均精度(average accuracy)和 Kappa 系数进行准确性评估。

2.2 圣罗莎(Santa Rosa)数据集检测结果和比较

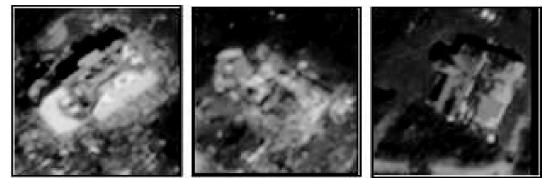
圣罗莎数据集的试验结果展示在图 6 和表 2 中。在灾害背景下, 影像中存在大量的伪变化和随机噪声, 传统的检测方法很难达到良好的检测

效果。在表 2 中,随机森林的各项指标均为最低。UNet 采用多层卷积结构,可以捕捉具有表征性的建筑物特征,区分建筑物是否受损。在遥感影像上,受损建筑物表现为复杂的光谱和纹理特征,单纯的卷积结构难以区分,UNet 存在明显的漏检情况。pix2pix 算法是典型的生成式模型,在生成器和判别器的对抗过程中自动学习具有稳健性的特征,不需要大量的样本。与 UNet 相比,pix2pix 对完好和损毁建筑物的检测精度分别提高了 0.04 和 0.01。与 UNet 相比,pix2pix 的检测效果更加平滑,但仍旧很难区分建筑物是否受损,recall 仅为 0.70 和 0.76。本文提出的 RS-GAN 采用多模态的检测模式,加入联合损失函数充分利用建筑物识别和损毁建筑物之间的潜在互利性,同时用建筑物识别结果指导损毁建筑物检测,检测结果拥有更加清晰的轮廓。RS-GAN 的 OA、AA 和 Kappa 均为最高,分别为 0.01、0.86 和

0.78。本文将建筑物识别 GAN 和建筑物损毁检测 GAN 的 loss 曲线展示在图 7 中,可以发现两者在相互对抗的过程中达到最佳效果。



(a) 完好或轻度损毁(不受干扰或建筑物部分损毁。屋顶瓦片元素缺失, 或可见裂缝。)



(b) 中度损毁或倒塌(损毁)(部分墙体或屋顶坍塌。)

图 5 建筑物损毁描述

Fig.5 Description of damage buildings

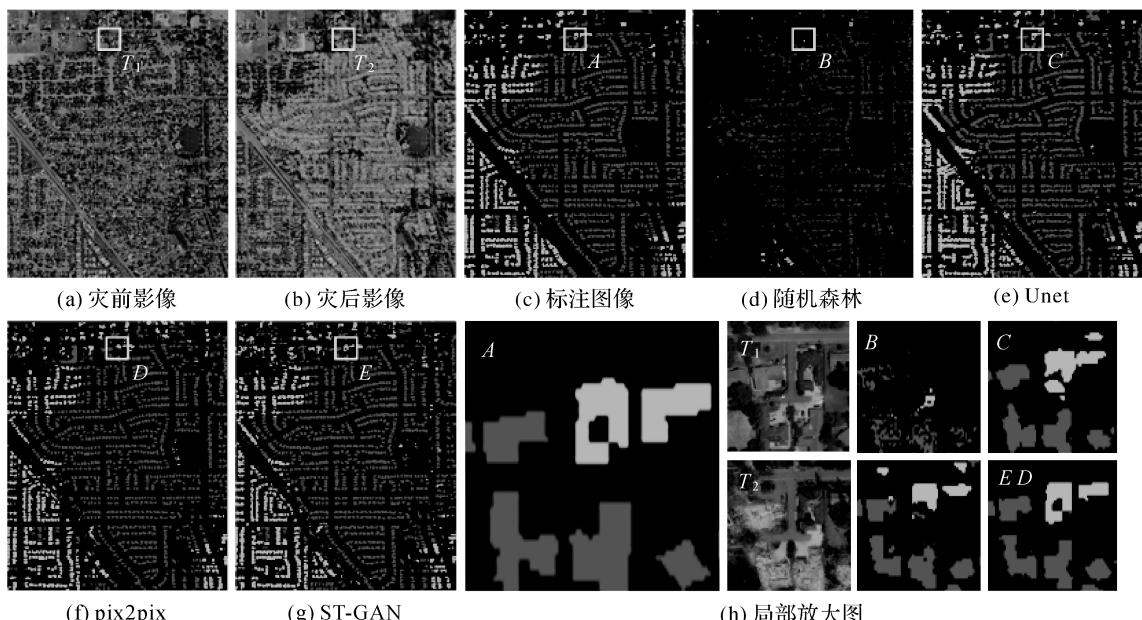


图 6 圣罗莎数据集检测结果

Fig.6 Detection results of Santa Rosa data sets

表 2 圣罗莎数据集检测结果及比较

Tab.2 Detection results and comparison of Santa Rosa data sets

评价指标	RF		UNet		pix2pix		RS-GAN		count
	精度	召回率	精度	召回率	精度	召回率	精度	召回率	
背景	0.79	0.96	0.94	0.93	0.92	0.95	0.94	0.94	4 948 837
完好	0.53	0.03	0.76	0.81	0.80	0.70	0.77	0.80	518 053
损毁	0.69	0.34	0.81	0.82	0.82	0.76	0.82	0.84	1 137 910
总体精度	0.78		0.90		0.89		0.91		-
平均精度	0.45		0.85		0.80		0.86		-
Kappa	0.28		0.76		0.73		0.78		-

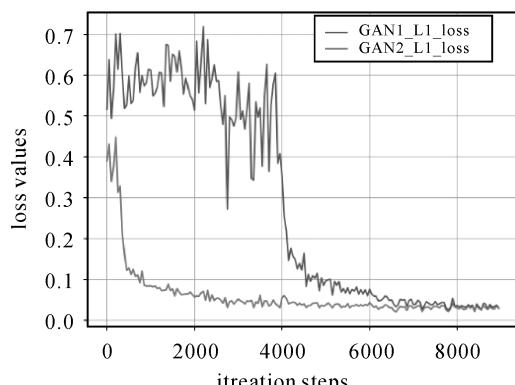


图 7 RS-GAN 在圣罗莎数据集上训练的 loss 曲线

Fig.7 Loss curves that RS-GAN trained on the
Santa Rosa data sets

2.3 密苏里(Missouri)龙卷风数据集检测结果和比较

为了检测 RS-GAN 的普适性,本文在另一个密苏里州龙卷风数据集上做了进一步的测试(见表 3 和图 8)。不同于火灾数据集,龙卷风破坏建筑物会产生大量建筑物残片,影响检测效果。在此试验中,RS-GAN 和标签之间拥有最高的吻合度,Kappa 值达到了最高的 0.55。随机森林难以检测出损毁建筑物,Kappa 值只达到了 0.27。UNet 虽然检出率较高但错检现象严重。pix2pix 和 RS-GAN 因为加入了对抗结构,可以学习到更具稳健性的典型特征,相比于其他方法检测效果有所提高。总的来说,RS-GAN 拥有最好的检测效果,OA 和 Kappa 均达到了最高的 0.87 和 0.55。

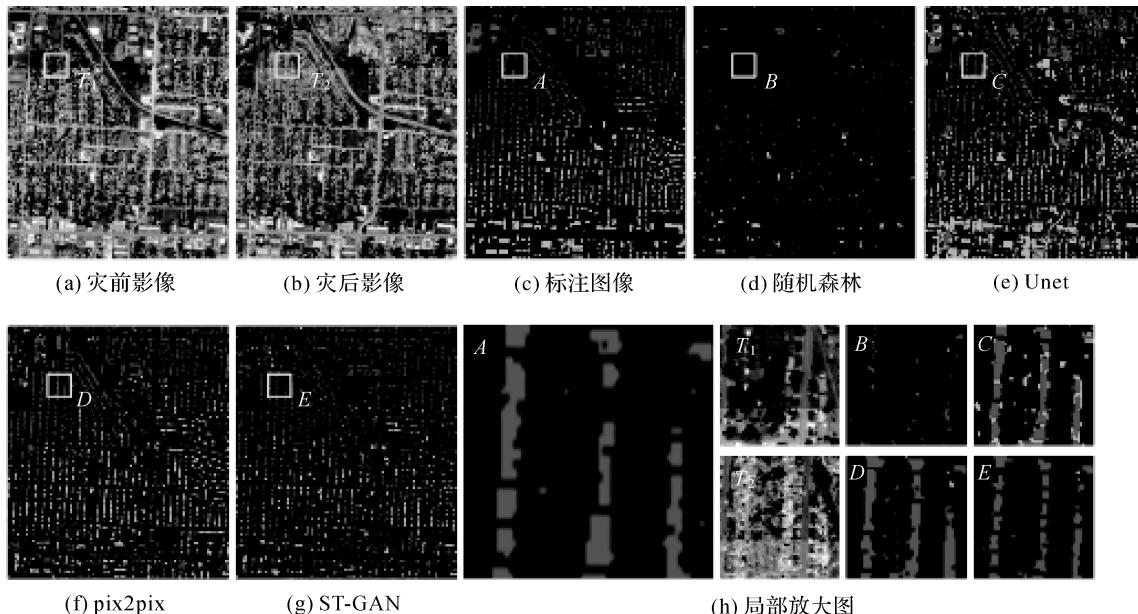


图 8 密苏里龙卷风数据集检测结果

Fig.8 Detection results of Missouri tornado data sets

表 3 密苏里龙卷风数据集检测结果及比较

Tab.3 Detection results and comparison of Missouri tornado data sets

评价指标	RF		UNet		pix2pix		RS-GAN		count
	精度	召回率	精度	召回率	精度	召回率	精度	召回率	
背景	0.87	0.98	0.98	0.82	0.95	0.89	0.94	0.94	12 196 705
完好	0.62	0.16	0.32	0.79	0.52	0.57	0.63	0.43	1 311 683
损毁	0.52	0.21	0.52	0.70	0.43	0.67	0.45	0.62	1 171 676
总体精度	0.86		0.81		0.85		0.87		-
平均精度	0.45		0.77		0.71		0.66		-
Kappa	0.27		0.50		0.52		0.55		-

3 讨 论

准确检测损毁建筑物对于灾害发生后的应急

救援有着重要的意义,但由于受损建筑物在遥感影像中大量的模糊像元,且灾前灾后影像存在季节、光照、地表覆盖等差异的影响,定位建筑物并

进行准确的损毁等级划分仍是一个巨大的挑战。除此之外,样本的获取困难和影像分辨率的限制,容易导致检测效率和精度低下。本文试验所选影像的分辨率为0.5 m,单个建筑物在图像上表示约为1000个像元且存在大量的模糊像元。在两组不同灾害影响下的数据集上检测了本文提出模型的性能,其中圣罗莎数据集具有充足的样本且类别均衡,密苏里数据集场景相对复杂,RS-GAN均取得了相对较好的检测效果。本文在一个环境更为复杂的多里安数据集上做了进一步的测试。

相比于以上两个数据集,多里安数据集建筑物更为分散且存在严重的类别失衡。测试的结果如图9和表4所示,可以看到在极端环境下各模型的检测精度整体偏低,RS-GAN拥有最好的检测效果,AA和Kappa均达到了最高的0.49和0.41。因此准确检测损毁建筑物除了需要准确定位建筑物外,更需要模型有更强的泛化能力,提取更具有特征性的特征,这将是笔者下一步研究的重点。

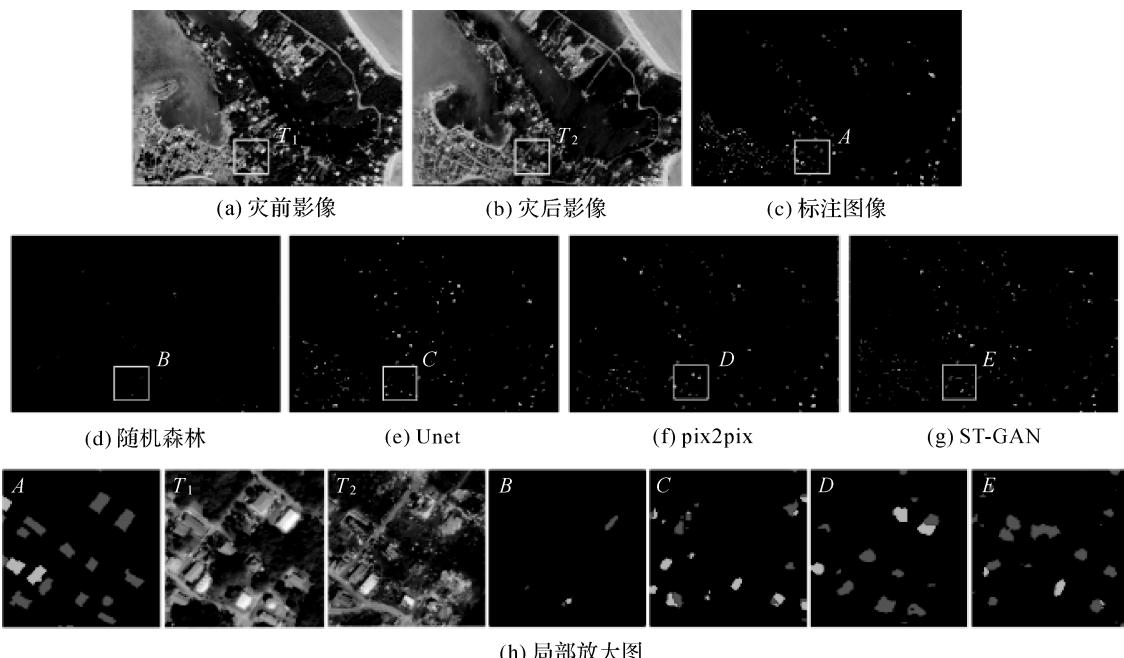


图9 多里安数据集检测结果

Fig.9 Detection results of Dorian data sets

表4 多里安数据集检测结果及比较

Tab.4 Detection results and comparison of Dorian data sets

评价指标	RF		UNet		pix2pix		RS-GAN		count
	精度	召回率	精度	召回率	精度	召回率	精度	召回率	
背景	0.97	1.00	0.98	0.99	0.98	0.99	0.98	0.99	4 425 531
完好	0.21	0.02	0.12	0.17	0.15	0.08	0.16	0.12	26 917
损毁	0.64	0.05	0.55	0.24	0.46	0.30	0.48	0.38	136 712
总体精度	0.97		0.96		0.96		0.96		-
平均精度	0.36		0.47		0.46		0.49		-
Kappa	0.09		0.35		0.36		0.41		-

4 结论

本文提出了一种RS-GAN模型来检测灾后建筑物的受损情况,并在圣罗莎和多里安数据集上进行了测试,结果表明,RS-GAN拥有明显的

检测优势。本文主要的贡献点在于:①提出了由两个pix2pix分支组成的多模态模型,将建筑物损毁信息提取任务分为建筑物识别和损毁建筑物检测两个子任务,充分利用了灾前灾后双时相影像信息优势。同时将建筑物检测结果加入损毁建

筑物检测,在训练过程中动态提供潜在区域建议,使检测结果具有更加清晰的轮廓。②设计了一种联合损失函数,将建筑物提取和损毁建筑物检测两个子网络合并为一个整体,充分利用了两个任务之间的潜在互利性,从而对损毁建筑物有着更强的检测能力。③RS-GAN 自动化程度较高,在输入灾前灾后影像及少量训练样本基础上,能够实现损毁建筑物自动检测。在未来的研究中,会在现有研究基础上继续提高模型的泛化能力,在更多数据集上做尝试,提升模型的检测能力。

参考文献:

- [1] 黄露. 基于机器学习的汶川震区滑坡灾害气象预警模型研究[J]. 测绘学报, 2020, 49(2): 267. DOI: 10.11947/j.AGCS.2020.20190061.
HUANG Lu. Research on meteorological early-warning model of landslides in Wenchuan earthquake area based on machine learning [J]. Acta Geodaetica et Cartographica Sinica, 2020, 49 (2): 267. DOI: 10.11947/j.AGCS.2020.20190061.
- [2] DONG Laigen, SHAN Jie. A comprehensive review of earthquake-induced building damage detection with remote sensing techniques[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 84: 85-99.
- [3] 陶和平, 刘斌涛, 刘淑珍, 等. 遥感在重大自然灾害监测中的应用前景:以 5·12 汶川地震为例[J]. 山地学报, 2008, 26(3): 276-279.
TAO Heping, LIU Bintao, LIU Shuzhen, et al. Natural hazards monitoring using remote sensing—a case study of 5·12 Wenchuan earthquake[J]. Journal of Mountain Science, 2008, 26(3): 276-279.
- [4] 眭海刚, 刘超贤, 黄立洪, 等. 遥感技术在震后建筑物损毁检测中的应用[J]. 武汉大学学报(信息科学版), 2019, 44(7): 1008-1019.
SUI Haigang, LIU Chaoxian, HUANG Lihong, et al. Application of remote sensing technology in earthquake-induced building damage detection[J]. Geomatics and Information Science of Wuhan University, 2019, 44 (7): 1008-1019.
- [5] YAMAZAKI F, SUZUKI D, MARUYAMA Y. Detection of damages due to earthquakes using digital aerial images [C]// Proceedings of the 6th International Workshop on Remote Sensing for Disaster Applications, Pavia, Italy: [s.n.], 2008.
- [6] 谢嘉丽, 李永树, 李何超, 等. 利用灰度共生矩阵纹理特征识别空心村损毁建筑物的方法[J]. 测绘通报, 2017 (12): 90-93, 102.
XIE Jiali, LI Yongshu, LI Hechao, et al. Recognition of damage buildings in hollow village based on texture feature of gray level co-occurrence matrix [J]. Bulletin of Surveying and Mapping, 2017(12): 90-93, 102.
- [7] 何浩, 刘修国, 沈永林. 基于视差的高分辨率遥感影像建筑物变化检测[J]. 遥感技术与应用, 2019, 34(6): 1315-1323.
HE Hao, LIU Xiuguo, SHEN Yonglin. Building change detection method considering the parallax for high resolution remote sensing image [J]. Remote Sensing Technology and Application, 2019, 34(6): 1315-1323.
- [8] 刘莹, 陶超, 闫培, 等. 图割能量驱动的高分辨率遥感影像震害损毁建筑物检测[J]. 测绘学报, 2017, 46(7): 910-917. DOI: 10.11947/j.AGCS.2017.20170035.
LIU Ying, TAO Chao, YAN Pei, et al. Graph cut energy driven earthquake-damaged building detection from high-resolution remote sensing images[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46 (7): 910-917. DOI: 10.11947/j.AGCS.2017.20170035.
- [9] 刘莹, 李强. 融合多特征的高分辨率遥感影像震害损毁建筑物检测[J]. 测绘与空间地理信息, 2018, 41(6): 61-64.
LIU Ying, LI Qiang. Damaged building detection from high resolution remote sensing images by integrating multiple features[J]. Geomatics & Spatial Information Technology, 2018, 41(6): 61-64.
- [10] 李强, 张景发. 不同特征融合的震后损毁建筑物识别研究[J]. 地震研究, 2016, 39(3): 486-493, 527.
LI Qiang, ZHANG Jingfa. Research on earthquake damaged building extraction by different features fusion[J]. Journal of Seismological Research, 2016, 39 (3): 486-493, 527.
- [11] SONOBE M. Characteristics of texture index of damaged buildings using time-series high-resolution optical satellite images[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 43: 1709-1714.
- [12] 袁玉, 申旭辉, 薛腾飞, 等. SAR 图像变化检测提取建筑物震害信息的研究综述[J]. 地壳构造与地壳应力文集, 2017(1): 131-143.
YUAN Yu, SHEN Xuhui, XUE Tengfei, et al. Review of researching for building earthquake damage information extraction based on SAR images change detection[J]. Bulletin of the Institute of Crustal Dynamics, 2017(1): 131-143.
- [13] 许志华. 基于低空影像和地面 LiDAR 数据的建筑物损毁评估方法研究[J]. 地理与地理信息科学, 2018, 34(4): 126.
XU Zhihua. Building damage assessment from unmanned aerial vehicle images and terrestrial LiDAR data[J]. Geography and Geo-Information Science, 2018, 34(4): 126.
- [14] SUN Long, WU Tao, SUN Guangcai, et al. Object detection research of SAR image using improved faster Region-Based convolutional neural network[J]. Journal of Geodesy and Geoinformation Science, 2020, 3(3): 18-28.
- [15] 叶昕, 王俊, 秦其明. 基于高分一号卫星遥感图像的建筑物震害损毁检测研究:以 2015 年尼泊尔 MS8.1 地震为例[J]. 地震学报, 2016, 38(3): 477-485, 509.
YE Xin, WANG Jun, QIN Qiming. Damaged building de-

- tection based on GF-1 satellite remote sensing image: a case study for Nepal MS8.1 earthquake[J]. *Acta Seismologica Sinica*, 2016, 38(3): 477-485, 509.
- [16] SAITO K, SPENCE R J S, GOING C, et al. Using high-resolution satellite images for post-earthquake building damage assessment: a study following the 26 January 2001 gujarat earthquake[J]. *Earthquake Spectra*, 2004, 20(1): 145-169.
- [17] LIU Sicong, DU Qian, TONG Xiaohua, et al. Multiscale morphological compressed change vector analysis for unsupervised multiple change detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(9): 4124-4137.
- [18] NEETI N, EASTMAN J R. Novel approaches in extended principal component analysis to compare spatio-temporal patterns among multiple image time series[J]. *Remote Sensing of Environment*, 2014, 148: 84-96.
- [19] 马国锐, 吴娇, 姚聪. 多尺度特征融合的建筑物及损毁语义分割[J]. 测绘工程, 2020, 29(4): 1-6.
- MA Guorui, WU Jiao, YAO Cong. Semantic segmentation of building and damage based on multi-scale feature fusion[J]. *Engineering of Surveying and Mapping*, 2020, 29(4): 1-6.
- [20] MIURA H, ARIDOME T, MATSUOKA M. Deep learning-based identification of collapsed, non-collapsed and blue tarp-covered buildings from post-disaster aerial images[J]. *Remote Sensing*, 2020, 12(12): 1924.
- [21] 左宗成, 张文, 张东映. 融合可变形卷积与条件随机场的遥感影像语义分割方法[J]. *测绘学报*, 2019, 48(6): 718-726. DOI: 10.11947/j.AGCS.2019.20170740.
- ZUO Zongcheng, ZHANG Wen, ZHANG Dongying. A remote sensing image semantic segmentation method by combining deformable convolution with conditional random fields [J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(6): 718-726. DOI: 10.11947/j.AGCS.2019.20170740.
- [22] DAI Yuchao, ZHANG Jing, HE Mingyi, et al. Salient object detection from multi-spectral remote sensing images with deep residual network[J]. *Journal of Geodesy and Geoinformation Science*, 2019, 2(2): 101-110.
- [23] 周阳, 张云生, 陈斯彪, 等. 基于 DCNN 特征的建筑物震害损毁区域检测[J]. *国土资源遥感*, 2019, 31(2): 44-50.
- ZHOU Yang, ZHANG Yunsheng, CHEN Siyang, et al. Disaster damage detection in building areas based on DCNN features [J]. *Remote Sensing for Land & Resources*, 2019, 31(2): 44-50.
- [24] LI Yundong, YE Shi, BARTOLI I. Semisupervised classification of hurricane damage from postevent aerial imagery using deep learning [J]. *Journal of Applied Remote Sensing*, 2018, 12(4): 045008.
- [25] HEZAVEH M M, KANAN C, SALVAGGIO C. Roof damage assessment using deep learning[C]// Proceedings of 2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR). IEEE, 2017: 6403-6408.
- [26] HEZAVEH M M, KANAN C, SALVAGGIO C. Roof damage assessment using deep learning[C]// Proceedings of 2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR). Washington, DC, USA: IEEE, 2017: 6403-6408.
- [27] GONG Maoguo, NIU Xudong, ZHANG Puzhao, et al. Generative adversarial networks for change detection in multispectral imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2310-2314.
- [28] LEBEDEV M A, VIZILTER Y V, VYGOLOV O V, et al. Change detection in remote sensing images using conditional adversarial networks[J]. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, XLII-2: 565-571.
- [29] ZHAO Wenzhi, MOU Lichao, CHEN Jiage, et al. Incorporating metric learning and adversarial network for seasonal invariant change detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(4): 2720-2731.
- [30] GUPTA R, GOODMAN B, PATEL N, et al. Creating xBD: a dataset for assessing building damage from satellite imagery[C]// Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Long Beach, CA, USA: IEE, 2019: 10-17.
- [31] VICKERY P J, SKERLJ P F, LIN J, et al. HAZUS-MH hurricane model methodology. II: damage and loss estimation[J]. *Natural Hazards Review*, 2006, 7(2): 94-103.
- [32] KELMAN I. Physical flood vulnerability of residential properties in coastal, eastern England[D]. Cambridge, UK: University of Cambridge, 2003.
- [33] BERNARDINI A, GIOVINAZZI S, LAGOMARSINO S, et al. The vulnerability assessment of current buildings by a macroseismic approach derived from the EMS-98 scale [C]// Proceedings of the 3rd International Congress of Seismic Engineering. Girona, Spain: [s.n.], 2007.

(责任编辑:张艳玲)

收稿日期: 2020-07-17

修回日期: 2021-08-03

第一作者简介: 葛小三(1971—),男,博士,教授。主要从事时空数据分析与时空信息服务。

First author: GE Xiaosan (1971—), male, PhD, professor, majors in spatio-temporal data analysis and spatio-temporal information service.

E-mail: hzhang@re.ecnu.edu.cn

通信作者: 赵文智

Corresponding author: ZHAO Wenzhi

E-mail: wenzhi.zhao@bnu.edu.cn