

改进的 U-Net 在建筑物变化检测中的应用

李仙华¹, 陈柏林¹, 陈欢¹, 张宏鸣¹, 王美丽¹, 冯志奎²

(1. 西北农林科技大学 信息工程学院, 陕西 杨陵 712100;

2. 西安电子科技大学 人工智能学院, 陕西 西安 710071)

摘要: 变化检测是对地观测应用中的一项重要任务。然而现有的基于深度学习的变化检测方法在高分遥感图像建筑物变化检测任务中仍存在变化对象和背景之间分界模糊、小变化目标漏检等问题。针对这些问题, 提出了一种基于高斯差分金字塔和注意力特征传递的遥感图像建筑物变化检测方法。该方法采用编码器解码器结构, 在编码阶段使用高斯差分金字塔获取双时相遥感图像多尺度边缘特征信息, 融合不同尺度下的边缘特征信息, 增强图像边缘特征表达能力。在解码部分引入注意力特征传递机制, 将高层语义信息与低层建筑物细节有效融合, 以捕获特征中的显著信息、抑制无效特征信息, 提升小变化目标的检测能力。该方法在公开的 LEVIR-CD、WHU-CD 数据集上进行训练和测试。实验结果表明, 相比于其他同类方法, 改进方法在对不同尺度建筑物目标的变化检测中展现了良好的适应性, 在保证较低算力消耗的基础上, 精确率、召回率、F1 和 Kappa 值方面均有较大提升。

关键词: 建筑物变化检测; 高斯差分金字塔; U-Net; 注意力机制; 特征融合

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2024)09-0030-08

doi: 10.20165/j.cnki.ISSN1673-629X.2024.0178

Application of Improved U-Net in Building Change Detection

LI Xian-hua¹, CHEN Bo-lin¹, CHEN Huan¹, ZHANG Hong-ming¹, WANG Mei-li¹, FENG Zhi-xi²

(1. School of Information Engineering, Northwest A&F University, Yangling 712100, China;

2. School of Artificial Intelligence, Xidian University, Xi'an 710071, China)

Abstract: Change detection is an important task in earth observation applications. However, existing deep learning based change detection methods still face problems such as blurred boundaries between changing objects and backgrounds, and missed detection of small changing targets in high-resolution remote sensing image building change detection tasks. A remote sensing image building change detection method based on Gaussian difference pyramid and attention feature transfer is proposed to address these issues. It adopts an encoder decoder structure and uses Gaussian difference pyramid to obtain multi-scale edge feature information of dual temporal remote sensing images during the encoding stage, which integrates edge feature information at different scales to enhance the ability of image edge feature expression. Introducing an attention feature transmission mechanism in the decoding section, effectively integrating high-level semantic information with low-level building details to capture salient information in features, suppress invalid feature information, and improve the detection ability of small change targets. The proposed method is trained and tested on publicly available LEVIR-CD and WHU-CD datasets. The experimental results show that compared with other similar methods, the improved method demonstrates good adaptability in detecting changes in building targets of different scales. While ensuring low computational power consumption, the accuracy, recall, F1, and Kappa values are significantly improved.

Key words: building change detection; Gaussian difference pyramid; U-Net; attention mechanism; feature fusion

0 引言

遥感图像变化检测是遥感领域的重要研究方向之一, 是监测地表变化的重要手段^[1]。随着城市化水平的不断提高, 针对建筑物更新状况的动态监测具有重大意义。虽然人工实地调研、巡查取证等城市建筑物

调查方式在精度上有所保障, 但效率低下, 耗费大量人力、物力和财力, 又无法全方位、实时监管。直接利用遥感图像进行建筑物变化检测能够大幅降低成本, 并提高检测效率^[2-4]。

传统的遥感图像变化检测一般使用人工特征建模

收稿日期: 2023-12-24

修回日期: 2024-04-25

基金项目: 国家自然科学基金面上项目(62276205); 陕西省林业科学院科技创新计划(SXLK2021-0214)

作者简介: 李仙华(1990-), 男, 硕士研究生, 研究方向为高分辨率遥感影像变化检测; 通信作者: 陈欢(1988-), 男, 博士, 讲师, 硕导, 研究方向为进化计算、深度学习和遥感图像变化检测。

方法,利用专家知识规划对目标区域进行特征表达,随后通过机器学习方法实现变化区域的检测^[5]。但是随着高分辨率尤其是超高分辨率遥感图像的普及,给传统机器学习方法带来了更多的压力。由于高分辨率遥感图像覆盖面积广,地物目标细节更加丰富,依赖于手工设计的底层或中层特征往往无法充分利用高分辨率遥感图像所包含的丰富地物信息,从而导致变化检测效果差、精度低。

近年来,依托于人工智能技术的发展,基于深度特征学习的神经网络在遥感图像建筑物变化检测领域中得到广泛的利用并取得了显著效果^[6]。与传统的机器学习方法不同,深度学习方法能够从海量标注数据中发现和学习图像中地物目标的几何结构和上下文关系,并将特征模型从传统的人工设计转变为机器自动学习深度抽象特征,结合分类器通过多层非线性网络实现地物的自动化识别和推理,进而完成建筑物的变化检测。Ronneberger 等^[7]提出 U-Net 网络,使用对称的编码器和解码器,并在编码器和解码器之间进行逐层跳跃连接,通过这种方法获得像素间的关系,实现像素的精确定位,但是由于其直接将编码器中的特征图和解码器中的特征图叠加,使得地物分类的边界粗糙。针对上述问题,很多学者又提出了一系列的新方法,例如,基于编码-解码的改进方法。陈良轩等^[8]提出了一种融合残差结构和注意力机制的编码-解码结构方法,加强了模型的特征提取能力,大大提高了遥感图像建筑物变化检测精度。基于面向对象的方法,刘宣广等^[9]在孪生神经网络的基础上,以图像分割对象为基本分析单元,在对象层级提取孪生神经网络图像特征,通过计算不同时相影像对象间的特征差异度,减少影像信息损失,提升检测结果精度。基于特征融合的方法,于海洋等^[10]提出一种融合多尺度混合注意力的建筑物变化检测模型,通过融合多尺度混合注意力模块提取的不同尺度的细节特征,增强模型准确性及鲁棒性。基于优化网络结构的方法,Zhou 等^[11]在 U-Net 结构基础上提出 UNet++网络,在 U-Net 网络结构中使用嵌套的密集跳跃连接,通过叠加不同层次的 U-Net 结构,减小了编码特征图和解码特征图之间的语义鸿沟。但其也导致参数量大大增加,计算复杂度升高,增加了过拟合的风险。基于优化卷积结构的方法,张翠军等^[12]采用非对称卷积块替换 U-Net 网络编码器部分的标准卷积操作,同时将注意力机制引入到 U-Net 网络结构中,在编码器和解码器特征进行跳跃连接前加入注意力机制调节特征权重,以此控制不同位置特征的重要程度,在一定程度上提高了变化检测精度,但是仍存在边缘不够完整的问题。高分辨率遥感影像中不同建筑物的差异明显,尺度多样^[13],如何有

效提取并融合不同层次特征、精确捕捉建筑物边界、减少小尺度目标漏检现象,是该文重点关注的问题。

受上述研究的启发,该文提出了一种基于高斯差分金字塔和注意力特征传递机制的高分辨率遥感图像建筑物变化检测方法-GAUNet,采用语义分割的思路进行建筑物的变化检测。该方法整体采用编码器解码器结构,在编码阶段使用高斯差分金字塔提取双时相遥感图像多尺度特征,改进特征提取效果,有效地提取图像不同尺度下的边缘特征信息。在解码阶段的跳跃连接过程中,使用注意力机制融合编码器中提取的特征信息,并采用自下而上的方式传递特征信息,充分融合不同阶段、不同分辨率的特征,捕获不同语义层特征中的显著信息,提升小目标变化检测的能力。最后,通过在公开数据集上与其他同类方法对比分析,验证了该方法的有效性。

1 预备知识

1.1 U-Net

U-Net^[7]是一个 U 型对称的编码器-解码器网络模型,其结构如图 1 所示。其中编码器部分主要负责提取图像特征,包括 4 个下采样层,每个下采样层均包含 2 个 3×3 的卷积,并以 1 个 2×2 的最大池化作为下采样操作,同时使用 ReLU 作为激活函数。解码器与编码器结构相似,主要区别是解码器将每层的下采样改为上采样操作,将提取到的特征图逐层恢复至原始分辨率,同时使用跳跃连接拼接下采样层提取到的特征图,并在最后一层使用 1 个 1×1 的卷积将特征向量映射到输出层。




图 1 U-Net 模型结构

1.2 高斯差分金字塔

大部分的边缘锐化方法使用增强高频信号的方法,但是因为随机噪声也是高频信号,很多锐化方法也增强了噪声。高斯差分算法去除了高频信号中所包含的随机噪声,增加了边缘和其他细节的可见性,因此可通过拼接高斯差分金字塔提取到的特征信息,增强边缘特征提取能力。

针对双时相遥感建筑图像变化检测任务,该文以高斯差分金字塔为基础构建双时相高斯差分金字塔。如图 2 所示,首先分别为双时相图像构建高斯差分金字塔,获得 d'_{ij} ,其中 i 表示金字塔的层数, j 表示任一

层中金字塔差分图像的层数, t 对应不同时相。针对双时相高斯差分金字塔构建任务, t 分别为 T_1, T_2 , 取每一层金字塔中第一层差分图像即 $j = 1$, 则双时相高斯差分金字塔 d_i 算式如下:

$$d_i = \text{abs}(d_{i,1}^{T_1} - d_{i,1}^{T_2}) \quad (1)$$

通过将双时相图像在不同尺度上进行多尺度的高斯差分处理, 提取出双时相图像多尺度差分特征, 能够有效地增强图像中的高频部分, 使得边缘和细节特征更加突出, 从而提取和增强图像中的边缘特征。




图 2 高斯差分金字塔结构示意图

1.3 注意力机制

深度学习领域的注意力机制的核心目标是从丰富的目标提取特征中选择出对当前任务更为关键的显著特征, 广泛应用于自然语言处理、目标检测以及语音识别等任务。卷积注意力模块 (CBAM)^[12] 是一种结合了空间和通道的注意力机制模块, 结构如图 3 所示, 包含了囊括全局信息的通道注意力子模块和关注局部信息的空间注意力子模块。




图 3 CBAM 结构示意图

CBAM 两个子模块分别进行通道与空间上的注意力计算, 进行特征压缩并生成权重, 再重新进行加

权。首先给定输入特征图 $F \in R^{C \times H \times W}$, 通过通道注意力机制得到通道注意力图 $M_C \in R^{C \times 1 \times 1}$, 将 F 与 M_C 两个矩阵的对应元素相乘后得到经通道注意力机制的特征图 $F_C \in R^{C \times H \times W}$; 然后将 F_C 经空间注意力机制得到空间注意力图 $M_S \in R^{1 \times H \times W}$; 最后将 F_C 与 M_S 两个矩阵的对应元素相乘后得到显著特征图 $F_R \in R^{C \times H \times W}$ 。通过图像特征的加权来关注重要特征, 抑制无效特征, 能够有效地获取目标显著特征, 在不明显增加参数和计算量的前提下提升网络性能。CBAM 的计算过程为:

$$F_C = M_C(F) \otimes F \quad (2)$$

$$F_R = M_S(F_C) \otimes F_C \quad (3)$$

式中, \otimes 为哈达玛积, 其定义为两个矩阵对应元素的乘积。

2 改进的 U-Net 模型

2.1 GAUNet

针对高分辨率遥感图像建筑物特征, 通过融合基于高斯差分金字塔的多尺度特征提取 (Multi scale Feature Extraction, MFE) 模块并结合基于 CBAM 的注意力特征传递 (Attention Feature Transmission, AFT) 模块来改进 U-Net, 设计了一种建筑物变化检测方法: GAUNet, 主要由编码部分和解码部分组成, 其架构如图 4 所示。在编码部分, 将每个下采样层最后一个模块输出的特征图组成自上而下的前向网络。同时, 为了保证能够从遥感图像中获得有价值的信息, 弥补下采样过程中损失的特征信息, 降低边缘及噪声的负面影响, 该文使用 MFE 模块提取出遥感图像多尺度特征并融合至前向网络的每一层, 得到融合多尺度信息的前向网络, 有效地增强图像中的高频部分, 使得边缘和细节特征更加突出, 最终实现边缘特征的找回。MFE 结构如图 5 所示。

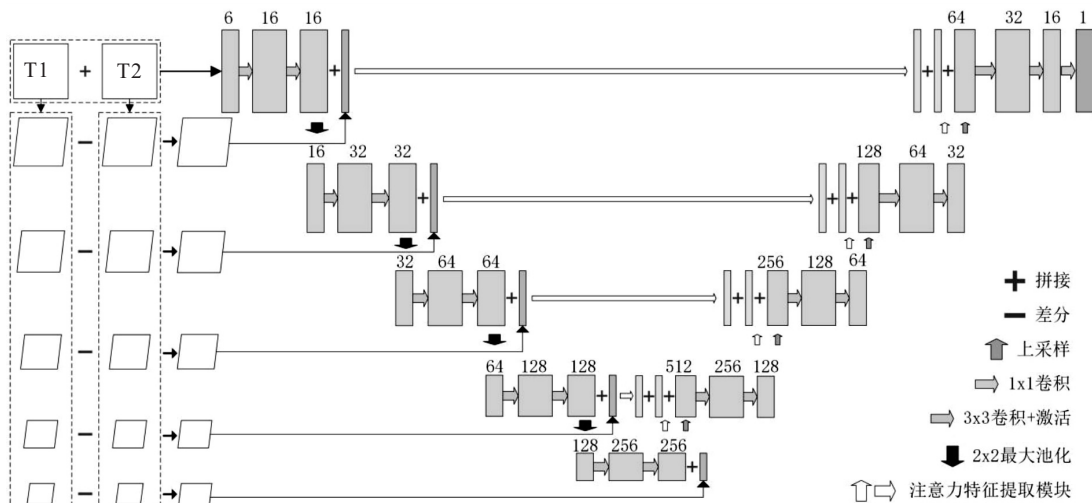


图 4 GAUNet 结构示意图




图 5 多尺度特征提取模块

在自上而下的前向网络中,高层特征包含丰富的语义信息,但缺少空间分辨率信息,低层特征具有较高的分辨率,但缺少语义信息。在解码部分,原始的 U-Net 网络通过跳跃连接将编码器和解码器之间的层级连接起来,使得解码器可以利用编码器中的语义信息来提高检测结果的准确性。但在建筑物变化检测任务中,由于遥感图像中包含众多干扰地物噪声信息,简单的跳跃连接未能充分关注并提取编码器中有效特征和细节信息^[14],使得建筑物目标与其他干扰信息难以有效区分,也无法准确定位小尺度建筑物。因此,对编码器中有效特征信息的增强以及无效特征信息的抑制十分重要。




图 6 注意力特征融合模块

该文在解码部分的跳跃连接过程中引入 AFT 模块,可使解码部分充分融合高层与低层信息,突出有用特征,抑制无效特征。其结构如图 6 所示。首先,对前向网络的每层特征图进行 CBAM 操作,然后同样对上采样层前一层输出的特征图进行 CBAM 操作,将这两部分相加得到用于特征增强的注意力权重图。特别的,当位于最底层时,上采样层前一层特征图即下采样层最后一层输出的特征图。最后将注意力权重图传递至上采样层第一个模块输入的特征图,实现语义信息与空间分辨率信息的融合,达到特征增强的目的。上采样层每增加一层,特征图尺寸变为前一层的 2 倍,当上采样层数与下采样层数相同时,特征图恢复至原始

分辨率大小。通过在最后一层上采样层添加 1 个 1×1 的卷积核,将通道数降至 1 并输出到分类器,即可得到最终的变化检测结果。

2.2 方法流程

方法流程如图 7 所示,数据集划分为训练集、验证集和测试集。首先在训练集中完成模型的训练,然后将训练好的模型放入验证集中进行验证,根据验证结果进行参数调试后,取验证集中结果最好的模型在测试集中进行变化检测,输出预测结果,最后将预测结果结合标签进行精度评价。

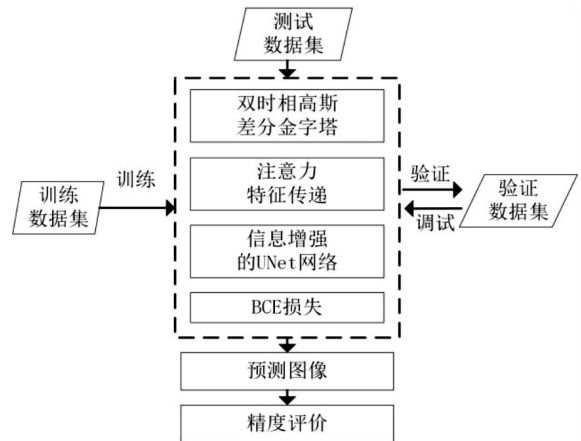


图 7 方法流程

3 实验与结果分析

3.1 实验数据集

该文采用 WHU 建筑物变化检测 (WHU-CD) 数据集^[15]和 LEVIR-CD 数据集^[16]作为实验数据集。训练时图像输入尺寸调整为 512×512 。

WHU-CD 数据集描绘了新西兰克赖斯特彻奇市的建筑变迁,覆盖了 2011 年 2 月发生 6.3 级地震并在随后几年重建的区域。数据集由 2012 年 4 月获得的航拍图像组成,其中包含 20.5 平方公里的 12 796 座建筑物(2016 年数据集中同一区域的 16 077 座建筑物),空间分辨率为 0.075 m,大小为 $32\ 507 \times 15\ 354$ 。按照训练集、验证集与测试集的比例(8 : 1 : 1)对裁剪后的数据集进行拆分,训练集图像对共计 2 153 对,验证集与测试集均为 270 对。

LEVIR-CD 数据集由谷歌地球 API 于 2002 年至 2018 年在美国德克萨斯州收集。它由 637 对大小为 $1\ 024 \times 1\ 024$,空间分辨率为 0.5 m 的图像对组成,涵盖别墅住宅、高层公寓、小型车库、大型仓库等各类建筑。按照训练集、验证集与测试集的比例(8 : 1 : 1)对裁剪后的数据集进行拆分,训练集图像对共计 2 040 对,验证集与测试集均为 254 对。

3.2 评价指标

为了定量评估 GAUNet 在遥感图像变化检测任务

中的表现,选取了精确率 P (Precision)、召回率 Re (Recall)、综合评价指标 $F1$ ($F1$ -score) 和一致性检验指标 K (Kappa coefficient) 对实验结果进行评估。其中, P 表示预测为正例并且确实是正例的部分, 占有所有预测为正例的比例; Re 表示预测为正例并且确实是正例的部分, 占有所有确实是正例的比例; $F1$ 表示精确率与召回率的调和平均数, 能够很好地兼顾精确率与召回率; K 表示模型预测结果和实际分类结果的一致性, 可以很好应对不平衡样本。各项指标算式如下:

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

$$Kappa = \frac{p_o - p_e}{1 - p_e} \quad (7)$$

$$p_o = \frac{\text{对角线元素之和}}{\text{整个矩阵元素之和}} \quad (8)$$

$$p_e = \frac{\sum_i \text{第 } i \text{ 行元素之和} \times \text{第 } i \text{ 列元素之和}}{(\sum \text{矩阵所有元素})^2} \quad (9)$$

式中, TP/TN 为模型正确预测的正(反)例样本, FN 为模型错误预测为负样本的正样本, FP 为模型错误预测为正样本的负样本。

3.3 实验环境与模型配置

实验基于 Ubuntu 18.04 系统, CPU 采用 Intel Xeon Gold 5318Y, 内存为 32 GB, GPU 采用 NVIDIA A40, 显存为 48 GB, 使用 CUDA11.4 进行加速。文中所用到的模型均在深度学习框架 Pytorch1.8 上使用 Python3.9 实现。

为验证所提模型的有效性, 在训练阶段, 实验为每

个模型针对同一数据集设置了相同的超参数: 所有模型在两个数据集均迭代 100 个训练轮数 (epoch), 批处理 (batch_size) 参数设置为 4, 使用随机梯度下降 (Stochastic Gradient Descent, SGD) 优化算法更新模型参数, 初始学习率设置为 0.001, 采用固定步长学习率调整策略。并将数据集中的两个时相的遥感图像进行通道合并得到 6 通道数据作为模型输入。

3.4 消融实验

该文使用 MFE 和 AFT 对 U-Net 模型进行改进, 为了验证所提出的两个改进点对模型所起到的作用, 将 U-Net 模型作为基准方法进行消融实验。实验采用 WHU-CD 数据集和 LEVIR-CD 数据集。可视化实验结果如图 8 和图 9 所示, 定量实验分析结果如表 1 和表 2 所示。为了达到控制变量的目的, 除了所要对比的改进点不同之外, 每组对比实验参数设置完全相同。

表 1 WHU-CD 数据集消融实验测试结果对比

MFE	AFT	P	Re	F1	K
×	×	0.871	0.700	0.776	0.766
√	×	0.846	0.790	0.817	0.795
×	√	0.884	0.758	0.816	0.808
√	√	0.866	0.836	0.850	0.832

表 2 LEVIR-CD 数据集消融实验测试结果对比

MFE	AFT	P	Re	F1	K
×	×	0.849	0.745	0.794	0.785
√	×	0.846	0.779	0.811	0.803
×	√	0.884	0.843	0.863	0.857
√	√	0.887	0.856	0.871	0.866




图 8 消融实验在 WHU-CD 数据集上的可视化结果




图9 消融实验在 LEVIR-CD 数据集上的可视化结果

从表1、表2中可以看出,在U-Net模型中单独加入MFE或AFT都可以提升模型变化检测的性能。当U-Net模型中仅加入MFE时,可以从评价指标上看出该模块对模型召回率指标有较大的提升,在两个数据集上分别提升了9个百分点和3.4个百分点,这是由于MFE弥补了U-Net在编码阶段丢失的特征信息,降低了边缘及噪声的负面影响,如图8(e)所示,变化区域噪点减少,同时边缘相对较光滑。当U-Net模型中仅加入AFT时,在两个数据集上的Kappa系数分别提升了4.2个百分点和7.2个百分点,这是因为AFT补充了解码阶段不同特征图之间的互补信息,使模型更加准确地学习到变化特征,如图8(f)所示,细小变化也能够检出。当同时加入MFE和AFT时,在提升模型特征提取维度的同时,也使得分类难度提高,使得精确率指标在WHU-CD数据集上略微下降了0.5个百分点,但在LEVIR-CD数据集上仍提升了3.8个百分点。从总体的评价指标来说,模型的性能得到了明显的提升,相比于不使用MFE与AFT模块,召回率分别提升了13.6个百分点和11.1个百分点,F1值分别提升了7.4个百分点和7.7个百分点,Kappa系数分别提升了6.6个百分点和8.1个百分点。

从分析消融实验的结果可以得出结论:该方法在遥感图像变化检测任务中的效果要优于改进前的基准模型,同时也验证了所提出的MFE和AFT模块的有效性。

3.5 对比实验

为了进一步验证文中方法的效果,将提出的GAUNet与其他建筑物变化检测方法进行对比实验并分析。U-Net^[7]是文中方法改进对象,U-Net++^[11]在U-Net的基础上引入了更多的上采样节点和跳跃连接,SAFNet^[17]则基于孪生网络的框架加以改进,SNU-Net^[18]在U-Net的基础上引入了孪生网络,AAANet^[19]

在FCN的基础上融合模糊区域不同层的差异特征,LCDNet^[20]通过聚焦模块降低模型计算量的同时融合多尺度特征提升模型精度。对比实验仍使用前文提到的WHU-CD数据集和LEVIR-CD数据集进行训练和验证,并使用统一的分类器输出检测结果。

不同方法在两个数据集上的定量实验对比结果如表3所示。从整体来看,SNUNet与SAFNet分别在两个数据集上取得了最差效果,U-Net++在两个数据集上的4种指标较略高于U-Net,其中,在LEVIR-CD数据集上,SAFNet取得了最差的Kappa系数,LCDNet表现优于AAANet,SNUNet表现优于U-Net++,这是由于U-Net++虽然在编码器和解码器之间有全连接将不同层次的特征融合,但SNUNet不仅能够链接不同层次的特征,而且加入了多层语义特征聚合和细化,使其能够有更少的漏检。而在WHU-CD数据集上,SNUNet取得了最差的召回率,AAANet与LCDNet的4种指标相差极小,U-Net取得了最好的精确率。

文中方法在WHU-CD数据集和LEVIR-CD数据集上都取得了不错的检测效果,F1值分别达到了0.850和0.871,与U-Net++相比分别提升了5.4个百分点和8.9个百分点,召回率分别达到了0.836和0.856,与U-Net++相比分别提升了2.7个百分点和13.8个百分点,Kappa系数分别达到了0.832和0.866,与U-Net++相比分别提升了4.6个百分点和9.3个百分点。原因在于GAUNet中MFE模块在编码阶段融合了多尺度的特征信息,减少了下采样过程中的信息损失;AFT模块可以充分融合高层语义信息与低层空间信息,增强了图像的关键特征,使模型能够更准确的定位目标信息,增强检测能力。同时从表3统计不同方法计算量与参数量的统计数据中可以看出,文中方法在取得相对较好的检测精度的同时,仍保持适度的计算量与参数量。

表 3 不同变化检测方法测试结果对比

方法	WHU-CD 数据集				LEVIR-CD 数据集				GFLOPs	Params/M
	P	Re	F1	K	P	Re	F1	K		
U-Net	0.871	0.700	0.776	0.766	0.849	0.745	0.794	0.785	13.733	7.764
U-Net++	0.784	0.809	0.796	0.786	0.858	0.718	0.782	0.773	67.649	9.046
SAFNet	0.830	0.489	0.615	0.602	0.755	0.402	0.525	0.511	19.091	0.309
SNUNet	0.794	0.451	0.575	0.561	0.875	0.820	0.847	0.840	27.44	12.03
AANet	0.844	0.827	0.835	0.827	0.871	0.747	0.804	0.796	24.214	15.824
LCDNet	0.843	0.825	0.834	0.828	0.882	0.824	0.852	0.849	8.125	0.83
GAUNet	0.866	0.836	0.850	0.832	0.887	0.856	0.871	0.866	4.129	1.554

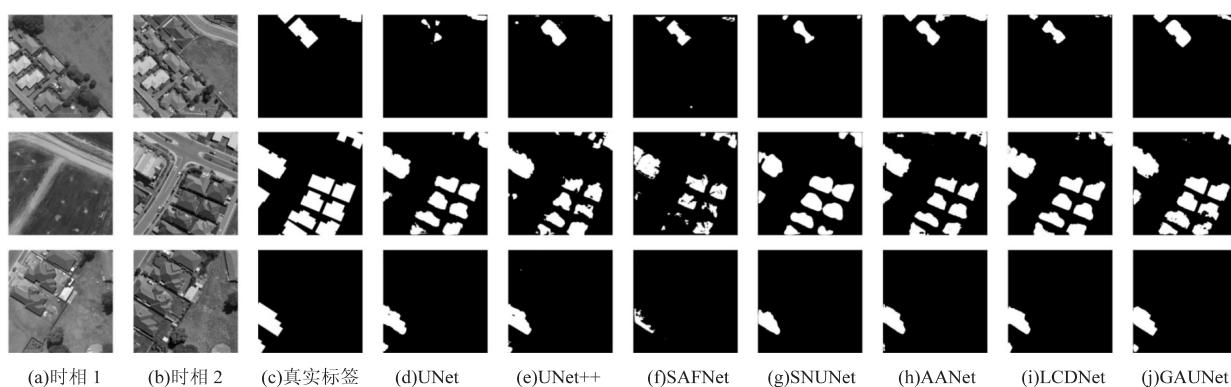


图 10 不同方法在 WHU-CD 数据集上的变化检测可视化结果




图 11 不同方法在 LEVIR-CD 数据集上的变化检测可视化结果

该文还选取了测试数据集中的部分变化图像来可视化实验结果。从图 10 和图 11 可以看出,SAFNet 在变化区域较小时会发生漏检的情况,无法很好地提取建筑物的边缘信息,同时对建筑物内部细节存在大量漏检。U-Net++与 U-Net 相比,检测的变化区域边界相对较光滑,噪点相对较少,但建筑物内部和边缘细节部分处理的还不够细化。SNUNet 与 AANet 则较为清晰准确,但仍有变化区域内部存在空洞、小目标漏检等问题。LCDNet 同样在部分建筑边缘以及小变化目标的检测中不够清晰、完整。文中方法具有最佳的可视化效果,变化建筑物边界光滑清晰没有锯齿状,噪声较少,同时变化区域连续完整,其目视结果与地面真值更为接近。同时,该方法在小尺度目标的检测方面具有一定的优越性,能够检测出小尺度建筑物的变化,伪变

化较少。因此,综合实验结果的定量分析和可视化分析,可以得出 GAUNet 模型针对建筑物遥感图像的变化检测,尤其是变化区域边界检测和小目标变化检测具有一定的优越性。

4 结束语

针对高分遥感图像建筑物变化检测中出现的边界模糊、小目标漏检等问题,提出一种基于高斯差分金字塔和注意力机制改进的 U-Net 网络模型。一方面,融合了多尺度特征的编码阶段,保留了更多尺度的建筑物特征,增强了边缘特征提取能力,使模型检测出的变化边缘平滑、完整。另一方面,通过在解码阶段融入多阶段、多分辨率的注意力特征,使模型能够聚焦于图像中变化的像素,有效恢复中小尺度建筑物的特征信息,

从而提升小尺度目标的检测能力。改进后的模型在变化检测的准确性和鲁棒性方面得到了很好的改善,且较原始 U-Net 模型,召回率、F1 值和 Kappa 系数都有提升。然而,改进后的模型虽然维持在较小的计算量,但模型性能提升不够明显,因此,后续研究将在保证计算效率的基础上进一步提高模型检测精度。

参考文献:

- [1] 张祖勋,姜慧伟,庞世燕,等. 多时相遥感影像的变化检测研究现状与展望[J]. 测绘学报,2022,51(7):1091-1107.
- [2] MOHANRAJAN S N, LOGANATHAN A, MANOHARAN P, et al. Fuzzy swin transformer for land use/ land cover change detection using LISS-III satellite data[J]. Earth Science Informatics,2024,17(2):1745-1764.
- [3] WANG L, ZHANG M, SHEN X, et al. Landslide mapping using multilevel-feature-enhancement change detection network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2023,16:3599-3610.
- [4] PATEL A, VYAS D, CHAUDHARI N, et al. Novel approach for the LULC change detection using GIS & Google earth engine through spatiotemporal analysis to evaluate the urbanization growth of Ahmedabad city[J]. Results in Engineering, 2024,21:101788.
- [5] 任秋如,杨文忠,汪传建,等. 遥感影像变化检测综述[J]. 计算机应用,2021,41(8):2294-2305.
- [6] SI SALAH H, GOLDIN S E, REZGUI A, et al. What is a remote sensing change detection technique? Towards a conceptual framework[J]. International Journal of Remote Sensing, 2020,41(5):1788-1812.
- [7] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// Medical image computing and computer-assisted intervention -MICCAI 2015. Munich: Springer,2015:234-241.
- [8] 陈良轩,于海洋,李英成,等. 一种融合注意力机制的建筑物变化检测模型[J]. 测绘科学,2022,47(4):153-159.
- [9] 刘宣广,李蒙蒙,汪小钦,等. 基于面向对象孪生神经网络的高分辨率遥感影像建筑物变化检测[J]. 遥感学报, 2024,28(2):437-454.
- [10] 于海洋,滑志华,宋草原,等. 一种融合多尺度混合注意力的建筑物变化检测模型[J]. 测绘工程,2024,33(1):47-56.
- [11] ZHOU Z, RAHMAN SIDDIQUEE M M, TAJBAKSHI N, et al. UNet++: a nested U-Net architecture for medical image segmentation[M]// Deep learning in medical image analysis and multimodal learning for clinical decision support: Vol. 11045. Granada: Springer,2018:3-11.
- [12] 张翠军,安冉,马丽. 改进 U-Net 的遥感图像中建筑物变化检测[J]. 计算机工程与应用,2021,57(3):239-246.
- [13] 冯权泷,陈泊安,李国庆,等. 遥感影像样本数据集研究综述[J]. 遥感学报,2022,26(4):589-605.
- [14] WANG H, CAO P, WANG J, et al. UCTransNet: rethinking the skip connections in U-Net from a channel-wise perspective with transformer[C]// Proceedings of the AAAI conference on artificial intelligence. [s. l.]: AAAI,2022:2441-2449.
- [15] JI S, WEI S, LU M. Fully convolutional networks for multi-source building extraction from an open aerial and satellite imagery data set[J]. IEEE Transactions on Geoscience and Remote Sensing,2019,57(1):574-586.
- [16] CHEN H, SHI Z. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection[J]. Remote Sensing,2020,12(10):1-23.
- [17] GAO Y, GAO F, DONG J, et al. Synthetic aperture radar image change detection via siamese adaptive fusion network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2021,14:10748-10760.
- [18] FANG S, LI K, SHAO J, et al. SNUNet-CD: a densely connected siamese network for change detection of VHR images[J]. IEEE Geoscience and Remote Sensing Letters,2022,19:1-5.
- [19] HANG R, XU S, YUAN P, et al. AANet: an ambiguity-aware network for remote-sensing image change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024,62:1-11.
- [20] LI J, LI S, WANG F. LCDNet: lightweight change detection network with dual-attention guidance and multiscale feature fusion for remote-sensing images[J]. IEEE Geoscience and Remote Sensing Letters,2024,21:1-5.