

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

刘宣广^{1,2}, 李蒙蒙^{1,2}, 汪小钦^{1,2}, 张振超³

1. 福州大学 数字中国研究院(福建), 福州 350108;

2. 福州大学 空间数据挖掘与信息共享教育部重点实验室, 福州 350108;

3. 信息工程大学 地理空间信息学院, 郑州 450001

摘要: 建筑物变化检测在城市环境监测、土地规划管理和违章违规建筑识别等应用中具有重要作用。针对传统孪生神经网络在影像变化检测中存在的检测边界与实际边界吻合度低的问题, 本文结合面向对象图像分析技术, 提出一种基于面向对象孪生神经网络 (Obj-SiamNet) 的高分辨率遥感影像变化检测方法, 利用模糊集理论自动融合多尺度变化检测结果, 并通过生成对抗网络实现训练样本迁移。该方法应用在高分二号和高分七号高分辨率卫星影像中, 并与基于时空自注意力的变化检测模型 (STANet)、视觉变化检测网络 (ChangeNet) 和孪生 UNet 神经网络模型 (Siam-NestedUNet) 进行比较。结果表明: (1) 融合面向对象多尺度分割的检测结果较单一尺度分割的检测结果, 召回率最高提升 32%, F1 指数最高提升 25%, 全局总体误差 (GTC) 最高降低 7%; (2) 在样本数量有限的情况下, 通过生成对抗网络进行样本迁移, 与未使用样本迁移前的检测结果相比, 召回率最高提升 16%, F1 指数最高提升 14%, GTC 降低了 9%; (3) Obj-SiamNet 方法较其他变化检测方法, 整体检测精度得到提升, F1 指数最高提升 23%, GTC 最高降低 9%。该方法有效提高了建筑物变化检测在几何和属性方面的精度, 并能有效利用开放地理数据集, 降低了模型训练样本制作成本, 提升了检测效率和适用性。

关键词: 遥感变化检测, 孪生神经网络, 面向对象多尺度分析, 模糊集融合, 生成对抗网络, 高分辨率遥感影像

中图分类号: P2

引用格式: 刘宣广, 李蒙蒙, 汪小钦, 张振超. 2024. 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. 遥感学报, 28(2): 437-454

Liu X G, Li M M, Wang X Q and Zhang Z C. 2024. Use of object-based Siamese neural network to build change detection from very high resolution remote-sensing images. National Remote Sensing Bulletin, 28 (2) : 437-454 [DOI:10.11834/jrs.20221627]

1 引言

建筑物变化检测是获取建筑物状态变化信息的常用手段, 在城市环境监测、土地规划管理和违章违规建筑识别等应用中具有重要作用 (周启鸣, 2011; 佟国峰等, 2015)。遥感变化检测泛指通过对比分析同一区域不同时期遥感数据来获得地物变化情况的技术 (孙晓霞等, 2011; 眭海刚等, 2018; Wen等, 2021)。面向中低等分辨率遥感影像, 国内外学者提出了众多基于像素的变化检测方

法, 如变化向量分析方法 (Change vector analysis) (陈晋等, 2001; 柳思聪等, 2011), 通过对比不同时相影像间的光谱差值来识别变化程度。此外, 分类后比较也是一种常用的变化检测方法 (Coulter等, 2016; Xu等, 2018; Paul等, 2021; Wang等, 2020), 但该类方法受影像分类精度影响较大。

随着高空间分辨率 (简称“高分”) 卫星数量的不断增加, 如美国 GeoEye 和 Worldview 系列、法国 Pleiades 系列, 以及中国高分系列卫星, 基于高分辨影像的建筑物变化检测获得了广泛关注。

收稿日期: 2021-10-19; 预印本: 2022-05-09

基金项目: 国家自然科学基金(编号:42001283); 福建省自然科学基金(编号:2021J01630); 福建省科技项目(编号:2022C0024)

第一作者简介: 刘宣广, 研究方向为遥感图像智能处理与分析、遥感变化检测。E-mail: 965377955@qq.com

通信作者简介: 李蒙蒙, 研究方向为高分辨率遥感图像智能处理、机器学习、城市土地利用分类。E-mail: mli@fzu.edu.cn

高分辨影像具有丰富的空间细节信息,可有效识别建筑物的精细变化,但高分辨影像通常在卫星拍摄时难以保持正射姿态,存在建筑物形变和位移问题,利用传统的基于像素的方法在高分辨影像变化检测中易产生较明显的检测噪音,识别精度较低(Wen等,2021)。

对于高分辨遥感影像变化检测,许多学者研究基于面向对象的变化检测方法。以图像分割对象为基本分析单元进行变化识别,可充分利用对象上下文信息,并突出高分辨影像的纹理和空间特征,能有效避免独立像元的光谱差异对检测结果的影响(Blaschke,2010;Liu等,2021),取得比基于像素检测方法更精确的结果(Desclée等,2006;冯文卿和张永军,2015;Huang,2018b;Wen等,2019)。但面向对象检测方法依赖于图像分割效果,特别是在复杂的城市环境中,分割对象难以精准的描绘地物对象几何轮廓,影响面向对象变化检测精度(黄鹏等,2020)。

随着深度学习技术发展以及在遥感图像专题信息提取中的成功应用,越来越多的研究学者开展基于深度学习的遥感变化检测研究,提出不少基于深度神经网络的变化检测方法(Khelifi和Mignotte,2020),如深度信念网络(Deep Belief Networks)、栈式自编码神经网络(Stacked AutoEncoder)(Zabalza等,2016)、孪生神经网络(Siamese neural network)等。其中,孪生神经网络使用两个相同的神经网络对输入图像进行深层特征提取,根据特征相似度来获取变化信息(Chopra等,2005;Nair和Hinton,2010;Yang等,2022)。如Zhang等(2019)使用轻量级伪孪生卷积神经网络(PSI-CNN)进行建筑物变化检测;随后Chen和Shi(2020)使用集成金字塔注意力机制的孪生神经网络进行建筑物变化检测;Li等(2021)使用改进的UNet++孪生神经网络对高分辨影像进行变化检测;Zhu等(2022)构建了一种孪生全局学习(Siam-GL)方法进行高分辨遥感影像变化检测。这些深度学习方法多在像素级进行变化检测,检测结果边界锯齿状明显,与实际变化边界吻合度不高。为解决这一问题,最近一些研究将面向对象和深度学习技术相结合进行变化检测,以图像分割对象为基本分析单元,有效降低了像素级变化检测中常见的椒盐噪声。如Liu等(2021)结合面向对象技术和卷积神经网络进行影像变化检测,获得了成功应用,但不同

尺度分割结果对检测效果的影响仍需进一步研究。

此外,使用深度学习进行遥感变化检测需要大量样本。为降低模型训练样本库构建的成本,Goodfellow等(2014)提出利用生成对抗网络GAN(Generative Adversarial Nets)提升样本库构建效率。随后,基于GAN模型,产生了许多该模型变体(Radford等,2016;Isola等,2017;Zhu等,2017;Karras等,2018)。另有研究将GAN与变化检测相结合,比如:王玉龙等(2019)创建一种基于GAN的新增建筑变化检测模型(CDGAN),提升了遥感影像中地面新增建筑物的检测精度;Peng等(2021)提出了一种基于GAN的半监督卷积网络,减少了训练数据集对于变化检测深度模型性能的限制。

现有的基于深度学习的建筑物变化检测方法并未充分利用VHR影像中丰富的几何、纹理信息,导致检测的建筑物变化存在边界模糊现象。尽管已有研究尝试利用GAN来减轻变化检测模型对训练数据集的依赖,但这类方法通常仅利用有限的标签数据进行训练,限制了其泛化能力,且模型结构复杂,训练成本高。为解决上述问题,本文提出了一种面向对象孪生神经网络(Obj-SiamNet)的高分辨率遥感影像变化检测方法,结合面向对象分析思想,解决传统孪生神经网络变化检测结果中检测边界与实际边界吻合度低的问题。同时,在决策级,构建了基于模糊集的多尺度自动融合方法,以避免单一图像分割尺度下Obj-SiamNet检测效果不佳的情况(这里的“尺度”指图像分割的精细程度)。此外,本研究使用循环生成对抗网络迁移模型训练样本,提升该检测方法的适用性。本研究可获取精细化的建筑物变化信息,从而为城市可持续发展决策的制定提供可靠的数据支持。

2 研究方法

基于面向对象孪生神经网络高分辨影像建筑物变化检测的技术路线如图1所示。首先,对双时相高分辨影像预处理,叠加双时相影像进行多尺度图像分割;然后,构建面向对象孪生神经网络,训练网络模型和检测影像变化信息。在此基础上,利用模糊集自动融合多尺度下的变化检测结果;最后,利用生成对抗网络将开放地理数据集样本信息迁移至目标域,降低样本集制作成本,提升检测模型的适用性。

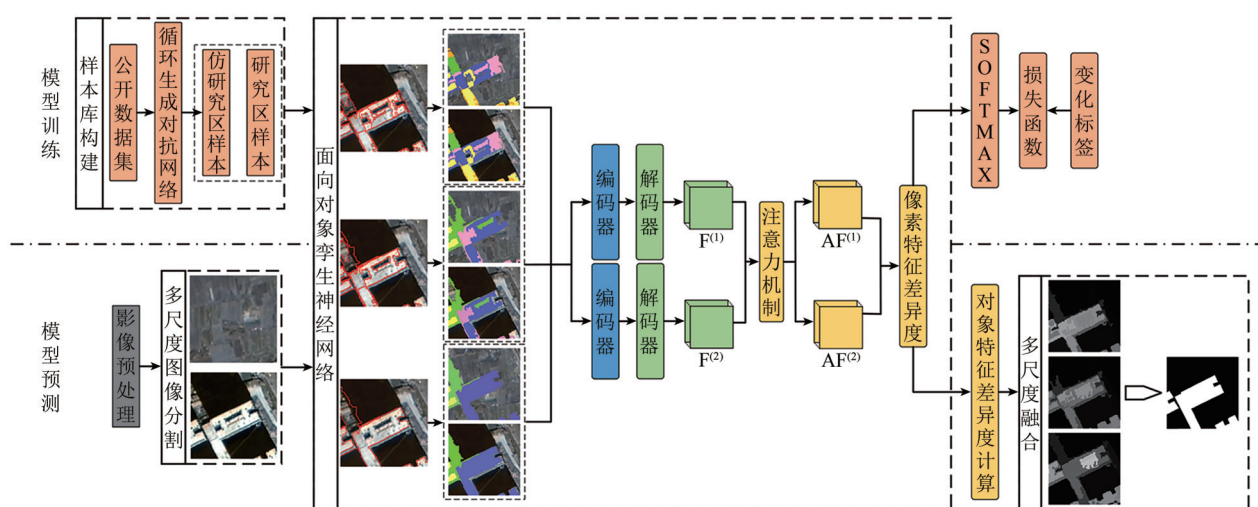
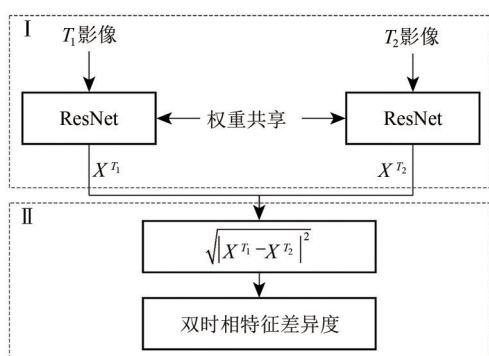


图1 基于Obj-SiamNet的建筑物变化检测技术路线

Fig. 1 The workflow of the proposed method for building change detection

2.1 面向对象孪生神经网络构建

广义上，孪生神经网络由两个相同或不同的神经网络耦合而成。图2 I 展示了由2个相同且共享权值的深度残差网络（Residual Network, ResNet）（He等，2016）组成的孪生神经网络，分别提取图像 T_1 和 T_2 的图像特征 X^{T_1} 和 X^{T_2} ，通过计算特征间欧氏距离量化特征差异度（沈雁等，2018）（图2 II）。借鉴面向对象图像分析思想，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，进而计算不同时相影像对象间的特征差异度。

图2 孪生神经网络结构图(X^{T_1} 和 X^{T_2} 分别表示 T_1 和 T_2 影像的语义特征)Fig. 2 The structure of Siamese neural network (X^{T_1} and X^{T_2} refer to the semantic features of T_1 and T_2 , respectively)

2.1.1 多尺度图像分割

本文采用多分辨率分割算法（multi-resolution image segmentation）（Benz等，2004）对叠加后的双时相影像进行图像分割，具体使用eCognition软

件中的多分辨率分割功能进行分割操作，通过设置不同的尺度（scale）参数可获得多个尺度下的分割对象。

2.1.2 孪生图像特征提取器构建

面向对象孪生神经网络Obj-SiamNet的特征提取器包含编码器和解码器两个模块。编码器的主干网络采用ResNet模型，ResNet通过在卷积神经网络中增加残差模块，使深层神经网络实现恒等变换，解决了随网络深度不断增加，模型性能降低的问题，提升模型准确率。根据网络深度不同，ResNet拥有ResNet18, 34, 50, 101等不同深度模型。He等（2016）指出ResNet模型的特征提取能力随网络层数增加而提升，但层数越深，性能提升幅度越小。综合考虑模型性能及训练成本，本文使用ResNet34构建Obj-SiamNet的编码器，并在编码器中保留ResNet34的4个残差模块，但移除全连接层和全局池化层（图3）。

此外，使用多个上采样模块作为Obj-SiamNet的解码器，并加入卷积块注意模块（Convolutional Block Attention Module）（Woo等，2018），用以学习深层图像特征的关键信息（图3）。

2.1.3 图像变化特征差异度计算

基于孪生影像特征，可计算不同时相影像的像素级特征差异度，并可根据图像分割对象，进一步计算不同时相影像对象级特征差异度。具体过程如下：

首先获取像素级特征差异度，令 $x_{ij}^{T_1}$ 和 $x_{ij}^{T_2}$ 分别

为图像 T_1 和 T_2 在像素 (i, j) 位置的特征向量, D 为该像素在不同时相间的特征差异度, 可通过计算 $x_{ij}^{T_1}$ 和 $x_{ij}^{T_2}$ 的欧氏距离获得:

$$D = \sqrt{|x_{ij}^{T_1} - x_{ij}^{T_2}|^2} \quad (1)$$

另外, 像素级特征差异度 D 在模型训练阶段也用来计算损失值, 本文采用对比损失函数 (Contrastive Loss) (Hadsell 等, 2006) 计算损失值, 该损失函数可有效处理孪生神经网络中成对匹配数据的关系:

$$L(D, M) = \frac{1}{2} \left(\frac{1}{n_u} \sum_{i,j} (1 - M_{ij}) \cdot D_{ij} + \frac{1}{n_c} \sum_{i,j} M_{ij} \cdot \max(0, m - D_{ij}) \right) \quad (2)$$

式中, M 为变化标签图, m 为设定的阈值, 只考虑

像素级差异度 D 在 0 至 m 之间, 差异度 D 超过 m 的, 则将其损失率记为 0。 n_u , n_c 分别代表标签图中未变化和变化像素数量, 计算公式为:

$$n_u = \sum_{i,j} 1 - M_{ij} \quad (3)$$

$$n_c = \sum_{i,j} M_{ij} \quad (4)$$

在对象层级检测建筑物变化, 可保留图像分割中获得的边界信息 (Tang 等, 2020), 提升检测边界与实际变化边界的吻合度。将像素级特征差异度 D 根据分割对象转换为对象级特征差异度 D_R , 计算公式为

$$D_R = \frac{\sum_{i,j} D_{ij}}{N_R} \quad (5)$$

式中, N_R 指图像对象 R 中像素的个数。

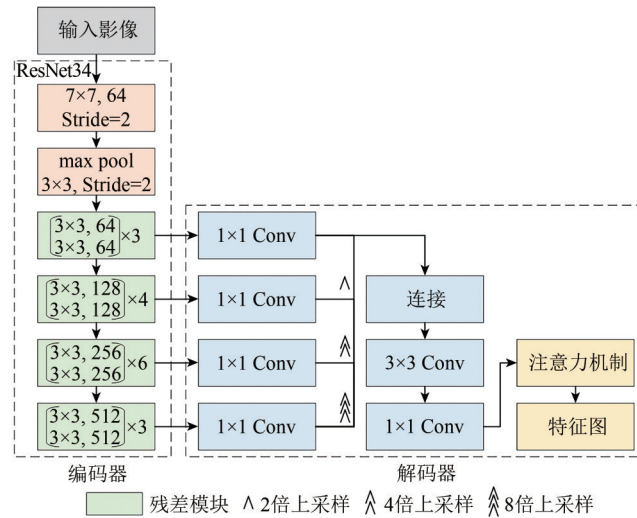


图3 Obj-SiamNet特征提取器结构

Fig. 3 Detailed structure of the Obj-SiamNet feature extractor

2.1.4 Obj-SiamNet模型训练和预测

同 ResNet 模型相似, Obj-SiamNet 模型训练和预测时需要输入尺寸为 256 像素×256 像素的图片。在制作 Obj-SiamNet 训练样本时, 考虑到图像分割对象尺寸和形状不同, 对每个分割对象样本, 以其质心为中心点定义一个尺寸为 256 像素×256 像素的矩形框, 将此矩形框包围的图像区域作为对应的 Obj-SiamNet 训练样本 (Zhang 等, 2018; Huang 等, 2018a)。同理, 在对每个分割对象进行预测时, 采用相同的方法将对象裁剪成尺寸为 256 像素×256 像素的图片。需要注意的是, 在对象级特征差异度计算时, 仅考虑图像对象与其矩形框重叠的区域 (图4)。

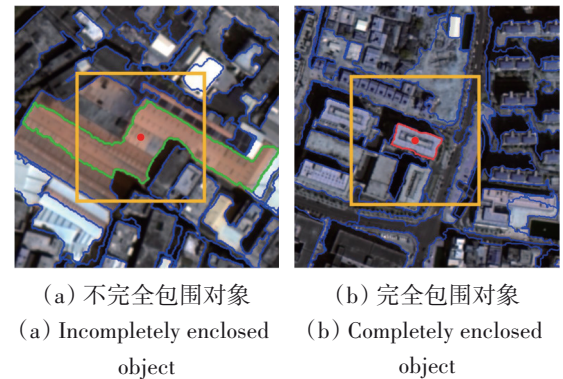


图4 不完全包围与完全包围对象的示意图

Fig. 4 Demonstration of incompletely enclosed and completely enclosed objects

2.2 多尺度变化信息融合

本文基于模糊集理论, 构建一组考虑检测结果不确定性的模糊集指标 (Li 等, 2016), 自动融合多尺度对象级特征差异度。

首先获取不同分割尺度下的对象级特征差异度 D_R , 定义隶属度函数 $f(D_R)$, 量化图像对象 R 在不同时相上变化的可能性 μ_R 。偏大型的 S 型隶属度函数在影像模糊分割处理时具有良好的鲁棒性和准确性 (Tobias 和 Seara, 2002), 因此使用 S 型隶属度函数计算 μ_R , 计算公式如下:

$$\mu_R = f(D_R, a, b, c) = \begin{cases} 0, & D_R \leq a \\ 2\left(\frac{D_R - a}{b - a}\right)^2, & a < D_R \leq b \\ 1 - 2\left(\frac{D_R - c}{c - b}\right)^2, & b < D_R \leq c \\ 1, & D_R > c \end{cases} \quad (6)$$

式中, 隶属度函数参数 a 、 b 、 c 定义了函数的形状 (图 5)。关于参数 c , 本文基于格网搜索法, 遍历对象差异度 D_R 值范围, 依次作为参数值 c 来计算隶属度并得到变化结果, 根据下式计算各变化结果的 $F1$ 指数。




图 5 S型隶属度函数

Fig. 5 S-type membership function

$$F1 = 2 \times \frac{R \times P}{R + P} \quad (7)$$

式中, R 为召回率, P 为精确率。

使用 S 型隶属度函数求得对象 R 在多层分割尺度上对应的不同隶属度值, 本文选择 3 层分割尺度, 对应隶属度值分别为 μ_1 、 μ_2 、 μ_3 。

借鉴 Li 等 (2016), 将 3 层分割尺度下的隶属度值 μ_1 、 μ_2 、 μ_3 中的最大值作为对象 R 变化的可能性 $\prod(CD_{R,p})$, 根据 μ_1 、 μ_2 、 μ_3 计算对象 R 未变化的可能性 $\prod(\overline{CD}_{R,p})$; 在此基础上, 计算对象 R 变化的确定性 $N(CD_{R,p})$ 和未变化的确定性 $N(\overline{CD}_{R,p})$ 。

具体计算如下:

$$\prod(CD_{R,p}) = \max(\mu_1, \mu_2, \mu_3) \quad (8)$$

$$\prod(\overline{CD}_{R,p}) = \max(1 - \mu_1, 1 - \mu_2, 1 - \mu_3) \quad (9)$$

$$N(CD_{R,p}) = 1 - \prod(\overline{CD}_{R,p}) \quad (10)$$

$$N(\overline{CD}_{R,p}) = 1 - \prod(CD_{R,p}) \quad (11)$$

若 $\prod(CD_{R,p}) > \prod(\overline{CD}_{R,p})$, 并且 $N(CD_{R,p}) > N(\overline{CD}_{R,p})$, 则自动判定对象 R 发生变化。

2.3 基于生成对抗网络的样本迁移

使用循环生成对抗网络 (Cycle GANs) (Zhu 等, 2017) 进行样本迁移, 生成具有多样高级语义特征的样本来充实训练集数据, 以降低样本库制作成本, 提升建筑物变化检测性能和 Obj-SiamNet 模型的适用性。具体地, Cycle GANs 由 2 个生成器和 2 个判别器组成, 判别器计算生成器所产生的数据与目标域数据的差异度, 并将结果反馈给生成器, 逐步指导生成器将随机噪声分布尽量拟合到目标域数据的真实分布 (Zhu 等, 2017)。经典生成对抗网络的训练数据要求成对匹配, 而 Cycle GANs 不受此限制, 并可将源域数据与目标域数据相互转换。该模型由 2 个对称的 GAN 结合, 每个 GAN 均包含一个生成器和一个判别器 (图 6)。

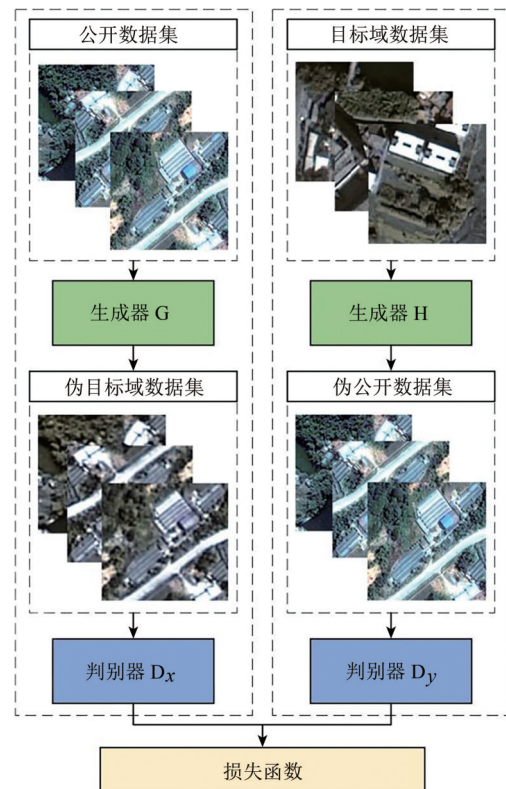


图 6 循环生成对抗神经网络结构图

Fig. 6 The structure diagram of the Cycle GANs

在 GF-2、GF-7 影像上制作少量研究区样本集，与公开数据集共同训练 Cycle GANs，将公开数据集转为仿研究区数据集。为避免正负样本不平衡问题，统计每个样本标签中变化像元占全部像元的比例，即样本变化程度。据此挑选研究区和仿研究区数据集中建筑物变化程度在 20%—80% 之间的样本用以构建模型训练样本库。

2.4 精度评价和性能评估

本文从属性和几何精度的角度评价变化检测结果与实际变化的吻合程度。选择精确率、召回率和 F1 分数评价属性精度，选择全局过分误差、全局欠分误差和全局总体误差评价几何精度 (Li 等, 2015)。将本方法与其他 3 种基于像素的变化检测模型进行对比分析，分别是：

(1) 视觉变化检测网络 (ChangeNet) (Varghese

等, 2019)：采用连体网络 and 全卷积网络模型将特征从图像对映射到视觉变化中。

(2) 基于时空自注意力的遥感图像变化检测模型 (STANet) (Chen 和 Shi, 2020)：使用 ResNet 网络进行特征提取，在特征提取模块后加入了金字塔注意力机制。

(3) 全卷积孪生神经网络模型 (Siam-NestedU-Net) (Li 等, 2021)：对语义分割网络 UNet++ 进行改进，用于变化检测的全卷积孪生网络。

3 数据处理与结果分析

3.1 研究区域和数据

本文选取 3 个研究区域，分别位于福建省的福州市、泉州市和浦城县。3 个研究区域的遥感影像见图 7。

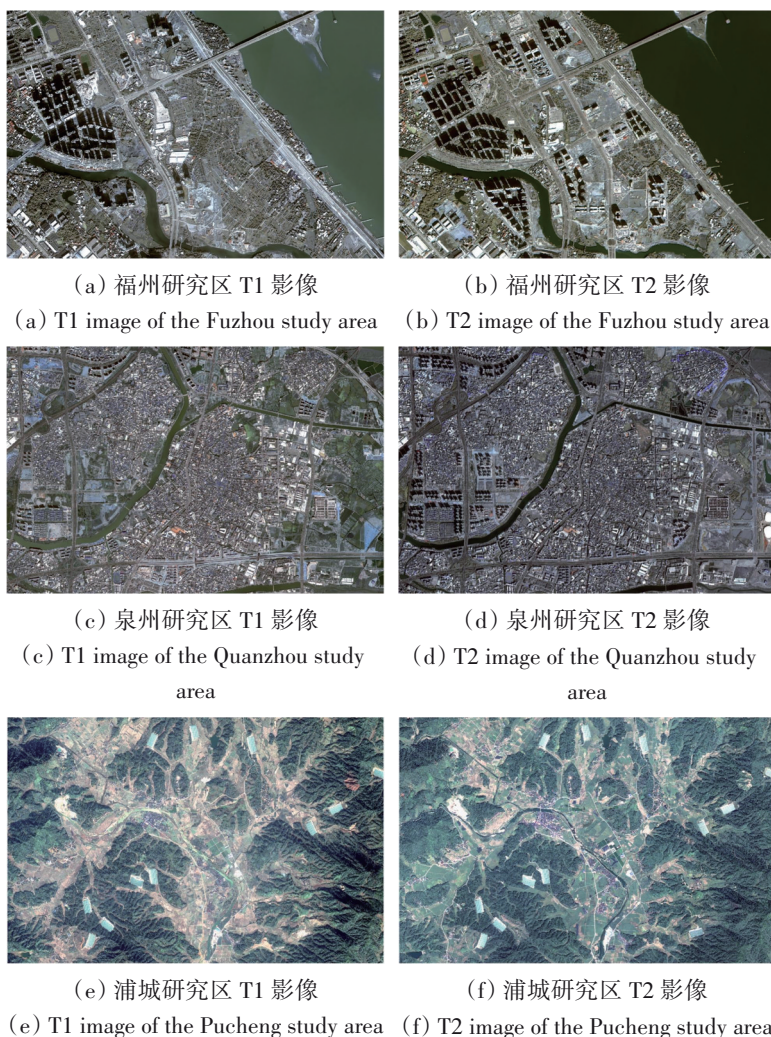


图 7 福州、泉州、浦城研究区的遥感影像

Fig. 7 Remote sensing images of these three study areas, i.e., Fuzhou, Quanzhou and Pucheng

福州研究区 (FZ) 的建筑物变化主要为高层建筑, 变化建筑物的空间分布较稀疏; 泉州研究区 (QZ) 内建筑物变化类型复杂, 涵盖低矮密集建筑群和高层建筑; 浦城研究区 (PC) 为非城市地区, 地形大部分为山区, 建筑物不集中且空间

分布错乱, 变化类型以小型密集建筑群和工厂建筑为主。本文所选择的影像数据, 由于受卫星拍摄角度和拍摄时太阳光照影响 (表 1), 各区域影像均非正射影像, 且存在较多建筑物阴影, 对开展变化检测方法研究具有一定的挑战性。

表 1 3 个研究区的影像数据信息表
Table 1 Detailed information of these three study images

研究区	时相	影像类型	影像日期	太阳方位角/(°)	卫星方位角/(°)
福州研究区 (FZ)	T1	GF-2	2016-12-07	165.833	95.864
	T2	GF-2	2020-02-18	152.569	89.208
泉州研究区 (QZ)	T1	GF-2	2017-09-14	150.543	87.044
	T2	GF-7	2021-02-22	155.473	233.290
浦城研究区 (PC)	T1	GF-2	2017-12-07	168.137	357.586
	T2	GF-2	2020-10-02	155.430	304.665


各研究区影像的类型和获取时间如表 1 所示。本研究在福州、浦城研究区选择相同传感器影像 (GF-2), 在泉州研究区选择不同传感器影像 (GF-2 和 GF-7) 进行实验, 以检验本方法在不同传感器的适用性。每幅 GF-2 影像包括一个 0.8 m 空间分辨率全色波段和 4 个 3.2 m 空间分辨率多光谱波段, GF-7 后视影像包含一个 0.65 m 空间分辨率全色波段和 4 个 2.6 m 空间分辨率的多光谱波段。采用 Gram-Schmidt 方法对影像的全色和多光谱波段进行融合, 使用双线性内插方法对融合后影像重采样, 获得分辨率为 0.8 m 的高分辨影像, 并进行几何校正、地理配准, 提高变化检测效率。

为构建模型训练样本库, 分别在福州市、浦城县 GF-2 遥感影像上各制作 1000 对 256 像素×256 像素的样本数据, 泉州市 GF-2、GF-7 遥感影像上制作 1368 对样本数据, 构成研究区数据集。此外, 本文对 CD_Data_GZ ([https://github.com/daifeng2016/Change-Detection-Dataset-for-High-Resolution-Satellite-](https://github.com/daifeng2016/Change-Detection-Dataset-for-High-Resolution-Satellite-Imagery)

Imagery) 公开数据集进行样本迁移, 获取 6400 对仿研究区数据。经过样本增强和筛选, 共制作了 13000 对训练样本, 按照 7 : 3 比例划分训练集和测试集。

3.2 多尺度图像分割

使用 eCognition 软件中多分辨率分割算法对双时相叠加影像分割, 选择包含欠分割和过分割情况的 3 个分割尺度 (scale) 分别为: 80、160、240。由于建筑物边界特征明显, 因此增大形状因子参数 (Shape), 将其设为 0.2, 经过多次分割实验, 本研究将紧密度参数 (Compactness) 设为 0.4。各研究区在 3 个分割尺度下的分割结果如图 8 所示。可知: 当 scale=80 时, 图像过分割, 单个建筑物被分割成多个对象, 分割结果破碎; 分割尺度为 scale=160 时, 建筑物分割较完整, 分割边界与实际边界更吻合; 当 scale=240 时, 图像欠分割, 多个建筑物或其他地物被分割为一个对象, 存在较严重的粘连问题。



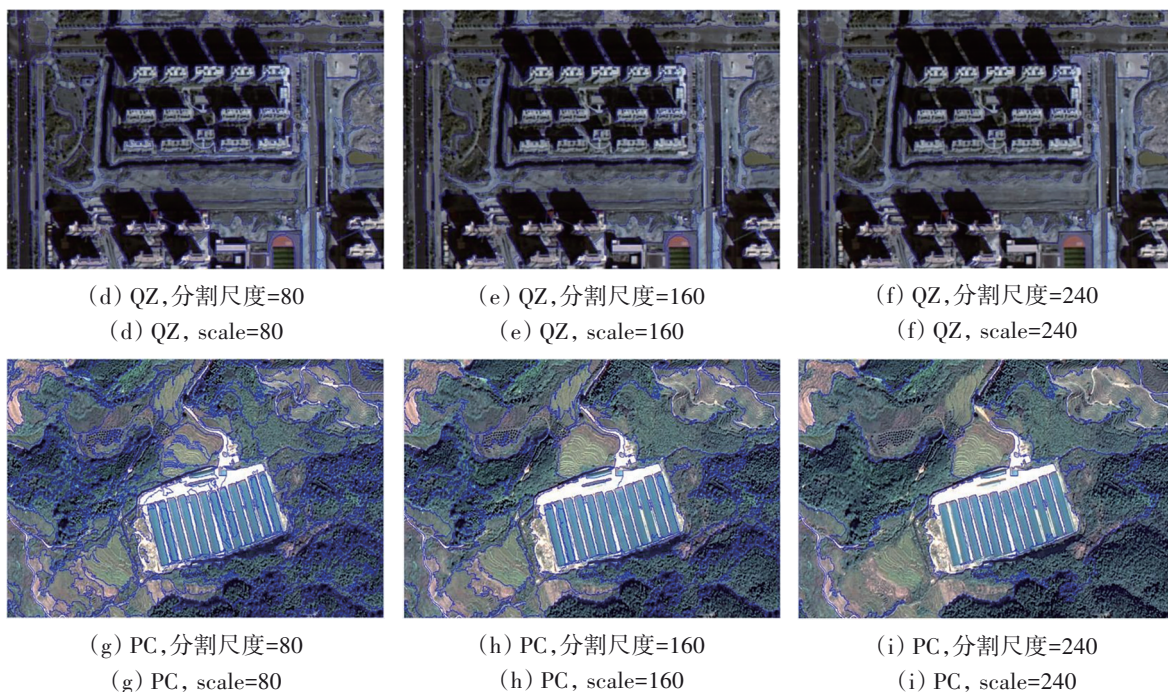


图8 各研究区在3个分割尺度下的对象分割结果


Fig. 8 The results of segmentation objects at three different segmentation scales in each study area

3.3 多尺度图像对象变化信息提取

首先,使用相同的模型训练参数和样本对不同深度ResNet构建的Obj-SiamNet训练、测试。训练模型时,将初始学习率设为 10^{-3} ,每经20次迭代,学习率减小为原来的十分之一。批次大小(batch_size)设为16,迭代次数(epoch)设为200,优化器采用Adam (Kingma 和 Ba, 2017)。结果表明:ResNet18, 34, 50, 101在测试集上的F1指数

分别为: 0.676、0.789、0.793、0.799, ResNet34效果优于ResNet18,且与ResNet50, 101效果相似,证实了使用ResNet34作为Obj-SiamNet的主干网络是兼顾模型性能和训练成本的最佳选择。

然后使用训练获取的Obj-SiamNet最佳模型检测研究区影像中的建筑物变化区域,获得像素级特征差异度,再根据分割对象转换到对象级特征差异度,详见图9。



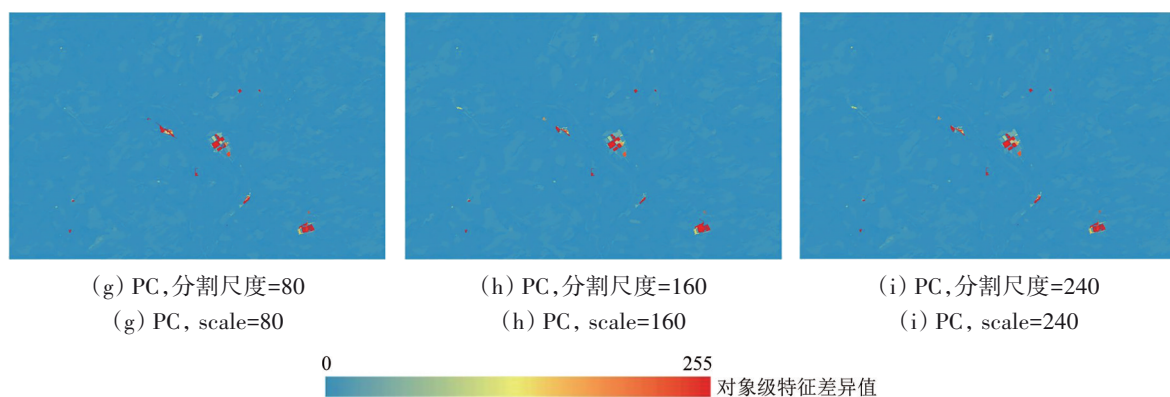



图9 各研究区不同分割尺度的对象级特征差异图

Fig. 9 Difference maps of object-level feature at different segmentation scales in each study area

图9对比了不同分割尺度下的对象特征差异。可见：在分割尺度为80、160时，3个研究区的对象特征差异图表示的建筑物变化信息较完整，建筑物对象边界与实际边界更加吻合；分割尺度为240时，图像欠分割造成对象差异图存在大区域粘连问题，但获取的变化信息较另外两个分割尺度的对象特征差异图更丰富。

3.4 多尺度变化信息融合

首先计算对象级特征差异度的隶属度。对于S型隶属度函数的参数 a 、 b 、 c ，设置 $a=0$ 、 $b=0.5 \times (a+c)$ 。在公开数据集CD_Data_GZ上，使用格网搜索法确定参数 c 取值。在参数 $c=77$ 时，变化结果的F1指数最高，因此将参数 c 设为77。

图10 格网搜索法结果($c=77$ 时,F1达到最大值)Fig. 10 The results of grid search method (F1-Score reaches its maximum value at $c=77$)

对研究区影像使用S型隶属度函数计算得到3个不同尺度下的对象隶属度值 μ_1 、 μ_2 、 μ_3 。根据 μ_1 、 μ_2 、 μ_3 ，计算变化可能性和变化确定性指数，根据模糊规则自动融合多尺度变化信息，获取融

合变化结果。

为验证本方法的有效性，选择FZ研究区局部子图(FZ-A)，将本方法得到的变化图与单一分割尺度使用自动阈值分割(Otsu, 1979)获得的变化图进行对比。由图11可知，单一分割尺度的检测结果会存在较多的漏检和误检。在图11(e)、图11(g)中(红框内)，分别存在明显的漏检和误检；在图11(e)中(黄框内)检测的建筑物变化区域存在严重误检，在图11(f)、图11(g)中(蓝框内)存在较严重的漏检问题，图11(f)、图11(g)中(红框内)检测的变化边界与真实建筑物变化边界吻合度较低。融合3个分割尺度获得的检测结果，较单一分割尺度检测结果在精确度和检测建筑物变化区域的完整度上有明显提升，召回率由最低0.34提升至0.66，全局总体误差最多降低7%，F1分数最高提升23%(表2)。

3.5 样本迁移结果分析

使用Cycle GANs将公开数据集转换为仿研究区数据集。在对Cycle GANs训练时，我们将学习率设为 2×10^{-4} ，迭代次数设为150次，批次大小设为8，最后共获得伪研究区数据集6400对。为验证该样本迁移方法的有效性，设置一组对比实验：

(1) 未使用Cycle GANs迁移样本：仅使用研究区数据集为样本，在由公开数据集(ImageNet)训练获得的ResNet34预训练参数基础上对Obj-SiamNet训练，用训练好的模型检测研究区变化。

(2) 使用Cycle GANs迁移样本：使用仿研究区和研究区数据集共同训练Obj-SiamNet，其余实验条件和实验步骤保持一致。

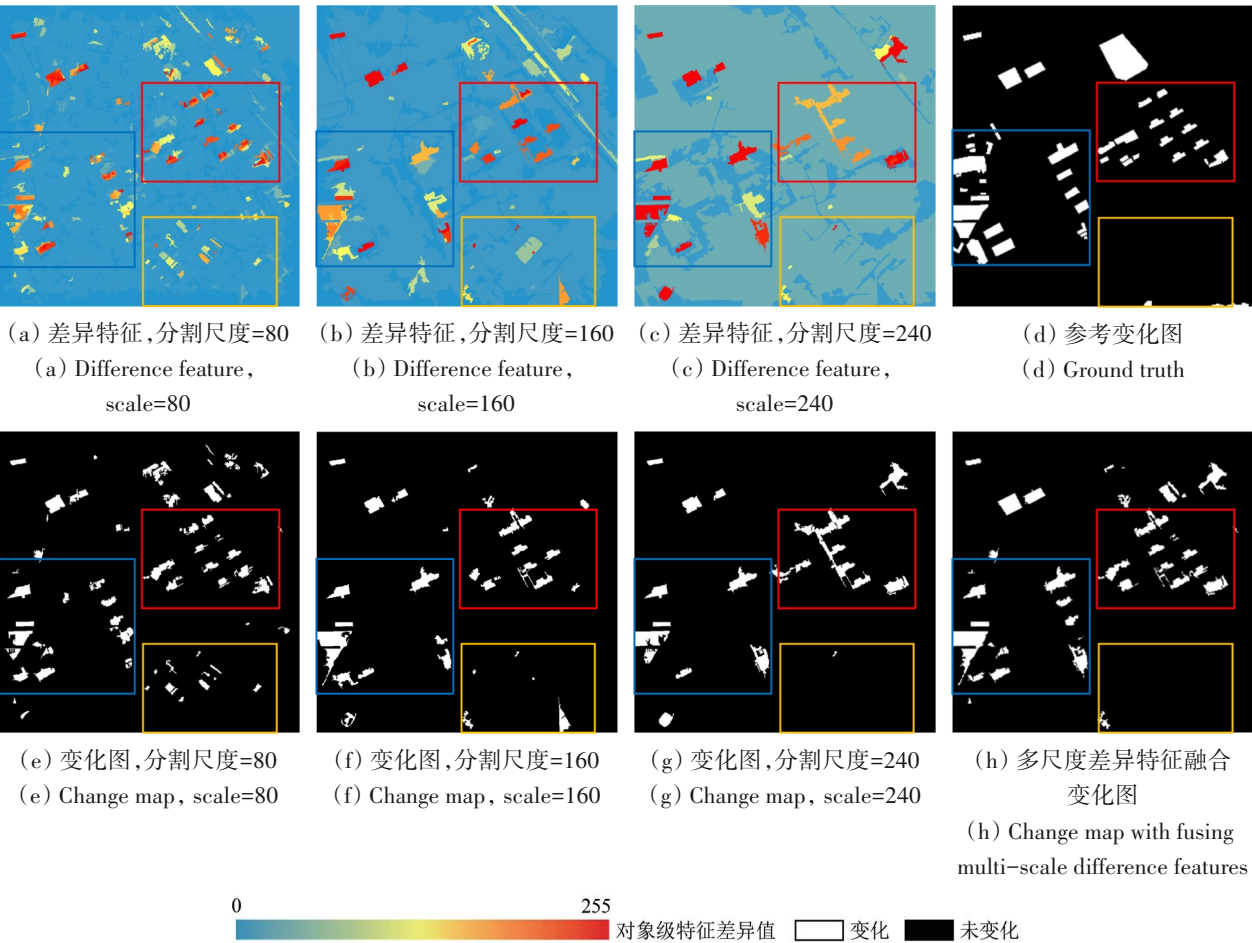


图 11 多尺度差异特征融合和单分割尺度差异特征获取的建筑物变化检测结果对比

Fig. 11 Comparison of building change detection results obtained by fusing multi-scale difference features with building change detection results obtained using a single scale difference feature

表 2 多尺度差异特征融合和单分割尺度差异特征获取的建筑物变化检测结果精度评价

Table 2 Evaluation of the accuracy of detection results: a comparison between those obtained by fusing multi-scale difference features and those obtained using a single-scale difference feature

精度指标	多尺度融合	Scale=80	Scale=160	Scale=240
F1 分数	68	50	47	43
精确率	71	63	67	60
召回率	66	41	36	34
全局总体误差	24	29	28	31
全局欠分误差	21	37	29	21
全局过分误差	21	13	20	28

注:黑体为最优值。

选取 FZ 研究区局部子图 (FZ-A)、QZ 研究区局部子图 (QZ-A), 对比使用 and 未使用 Cycle GANs 迁移样本的实验结果。图 12 展示了在实验区

FZ-A 和 QZ-A 样本迁移前后的建筑物变化检测结果。可知: 使用样本迁移的建筑物变化检测结果精确度更高, 实验区 FZ-A 的精确率由 71% 提升至 76%, QZ-A 的精确率由 61% 提升至 74%。有效改善了漏检现象, 召回率最高提升 16%, F1 分数最高提升 14%, 全局总体误差降低 9% (表 3)。

3.6 模型对比

使用 Obj-SiamNet 对福州研究区子图 (FZ-B) 进行变化检测, 并与其他 3 种模型对比。由图 13 可知, Obj-SiamNet 的检测结果破碎度较低, 能够较完整的检测出建筑物变化区域, 漏检现象得到明显改善。而 ChangeNet 检测结果存在较多漏检现象; 加入金字塔注意力模块的 STANet 对于光照变化引起的错检现象有较明显改善, 精确率较高, 但提取的变化区域破碎现象严重, 漏检严重; Siam-NestedUNet 的检测结果存在较多错检漏检现象。由表 4 可知, 本文提出的 Obj-SiamNet 相比于

其他3种方法在召回率上有较大提升, 最高提升了32%, 全局过分误差最高降低了23%, 相比于Siam-NestedUNet方法, 本方法在所有指标上均有明显提升。

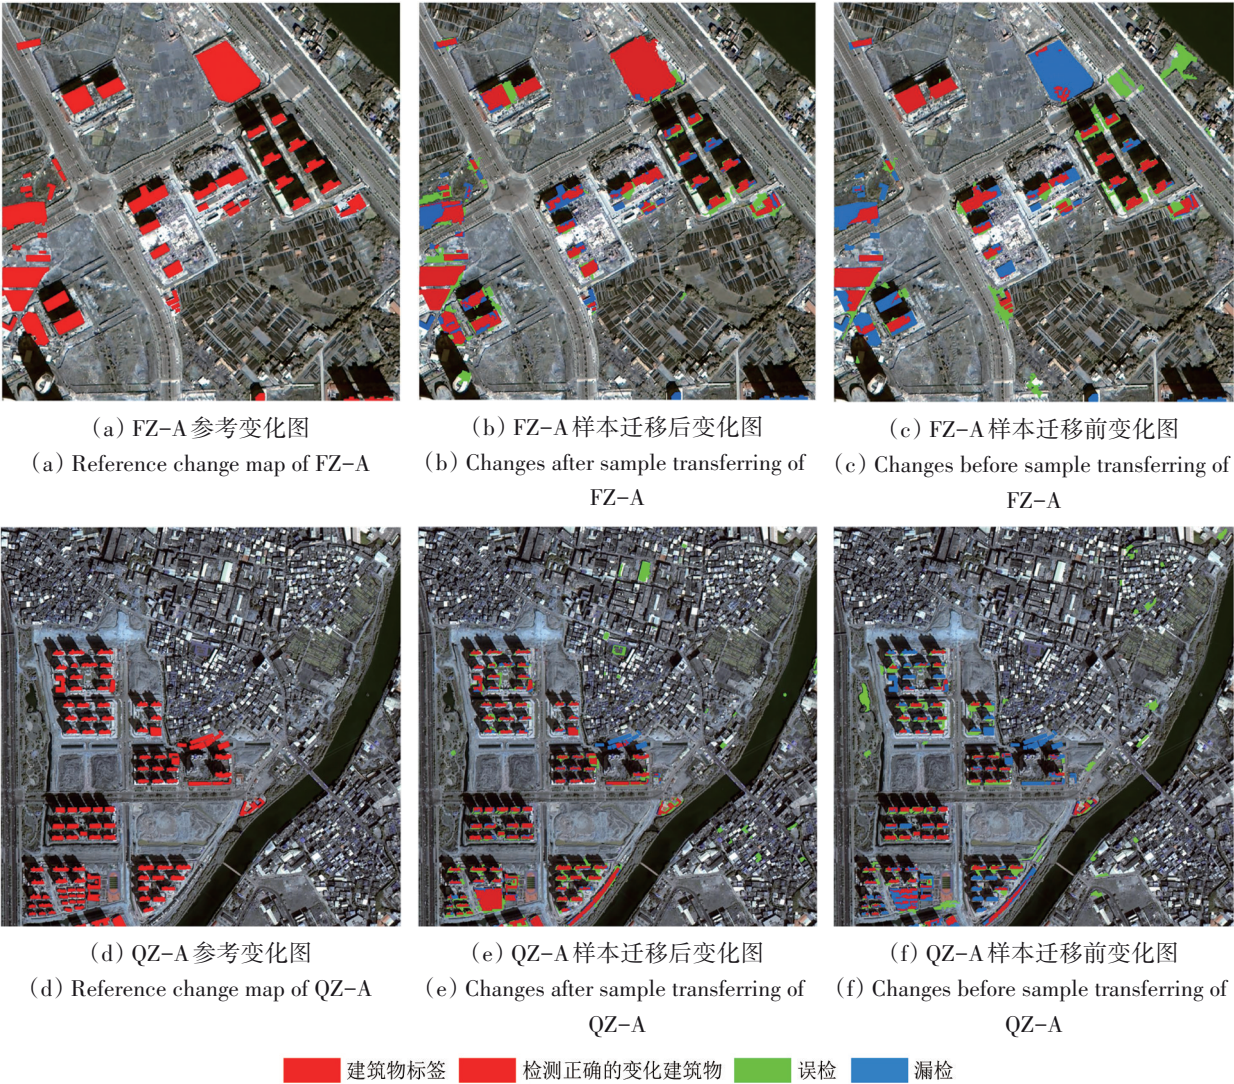


图 12 样本迁移前后变化结果图

Fig. 12 Comparison of detected changes before and after sample transferring

表 3 FZ-A 和 QZ-A 研究区在应用样本迁移策略前后的建筑物变化检测结果精度评价

Table 3 Evaluation of the accuracy of building change detection results before and after using the sample transfer strategy in the FZ-A and QZ-A study areas

评价指标	FZ-A 研究区精度		QZ-A 研究区精度	
	迁移前变化图	迁移后变化图	迁移前变化图	迁移后变化图
	/%			
F1 分数	68	74	64	78
精确率	71	76	61	74
召回率	66	72	67	83
全局总体误差	24	21	29	20
全局欠分误差	21	17	27	13
全局过分误差	21	22	23	23

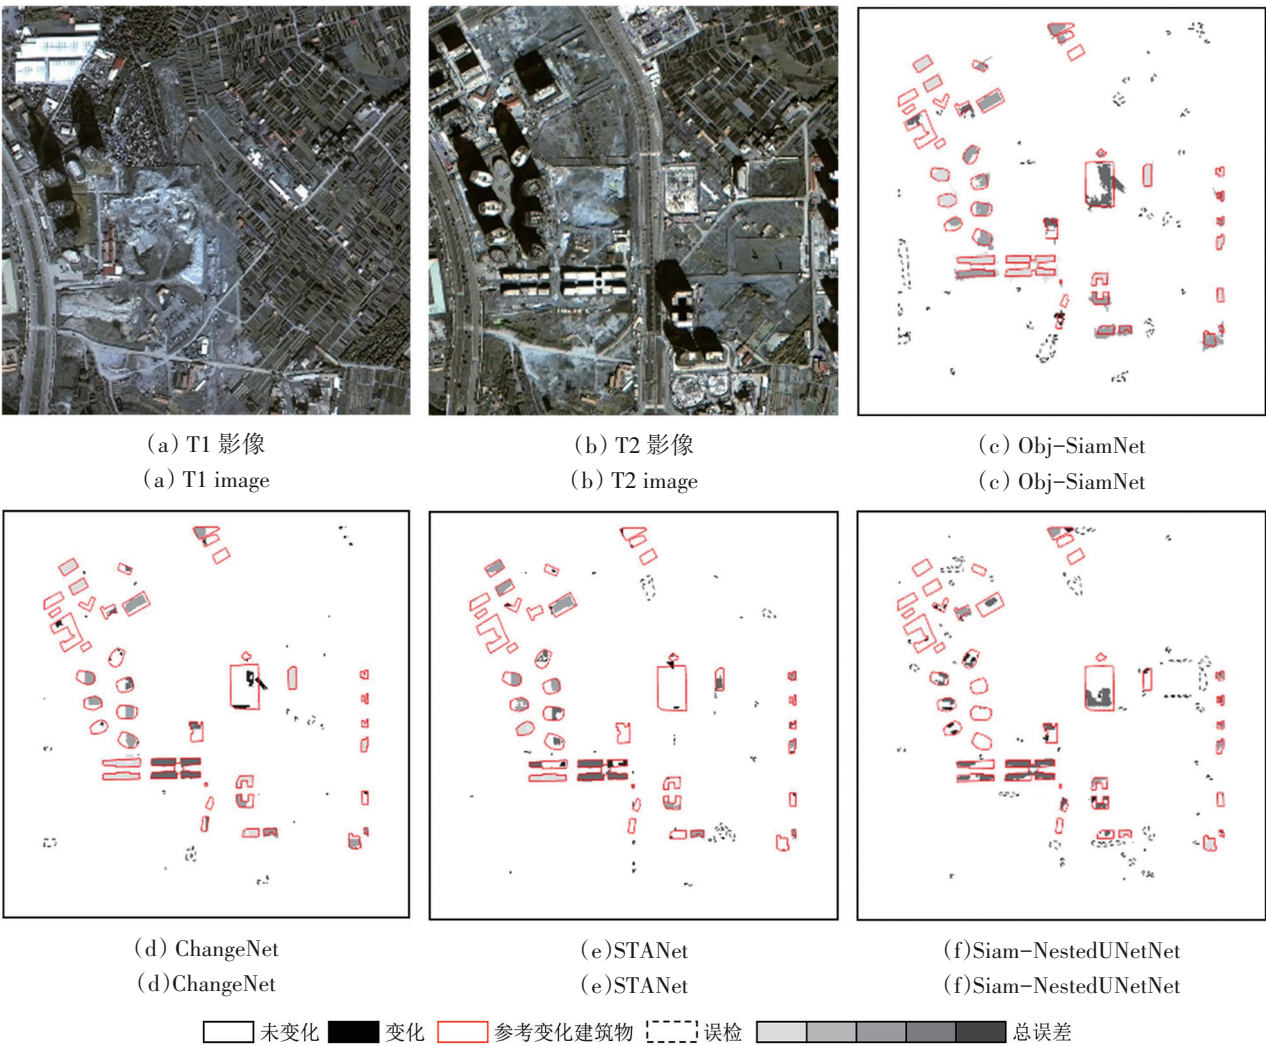


图 13 各方法在 FZ-B 区域中检测到的变化建筑物的面向对象评价结果

Fig. 13 Object-based evaluation results of different methods in the FZ-B area

表 4 各方法获取的建筑物变化检测结果精度评价

Table 4 Evaluation of the accuracy of building change detection results obtained by each method

模型	F1 分数	精确率	召回率	全局总体误差	全局欠分误差	全局过分误差
ChangeNet	54	69	44	29	37	10
STANet	45	77	31	32	42	8
Siam-NestedUNet	40	61	29	29	41	5
Obj-SiamNet	63	64	61	23	19	20

注:黑体为最优值。

进一步对比 Obj-SiamNet 与其他 3 种方法的检测结果细节图,由图 14 可知,STANet 在检测具有不规则形状的小型密集建筑物时,检测结果的变化边界与实际变化边界吻合度较低(图 14 (a)),且存在较多漏检现象(图 14 (b) 和 (c)); Siam-Nested-UNet 误检严重; ChangeNet 检测结果破碎度高(图 14 (c))。综上,在不同类型的建筑物变化场景下,Obj-SiamNet 检测的变化边界与实际变化边

界吻合度最高,且显著降低检测结果的破碎现象。
使用本方法得到的 3 个研究区的完整变化检测结果如图 15 所示。由表 5 可知,3 个实验区的检测结果召回率最高达 83%,精确率最高为 87%。其中,福州研究区检测的变化边界与实际变化边界更吻合,泉州研究区召回率和精确率分别为 83%、74%,但由于小型密集建筑物分割不精确,导致检测结果存在大片区域粘连。

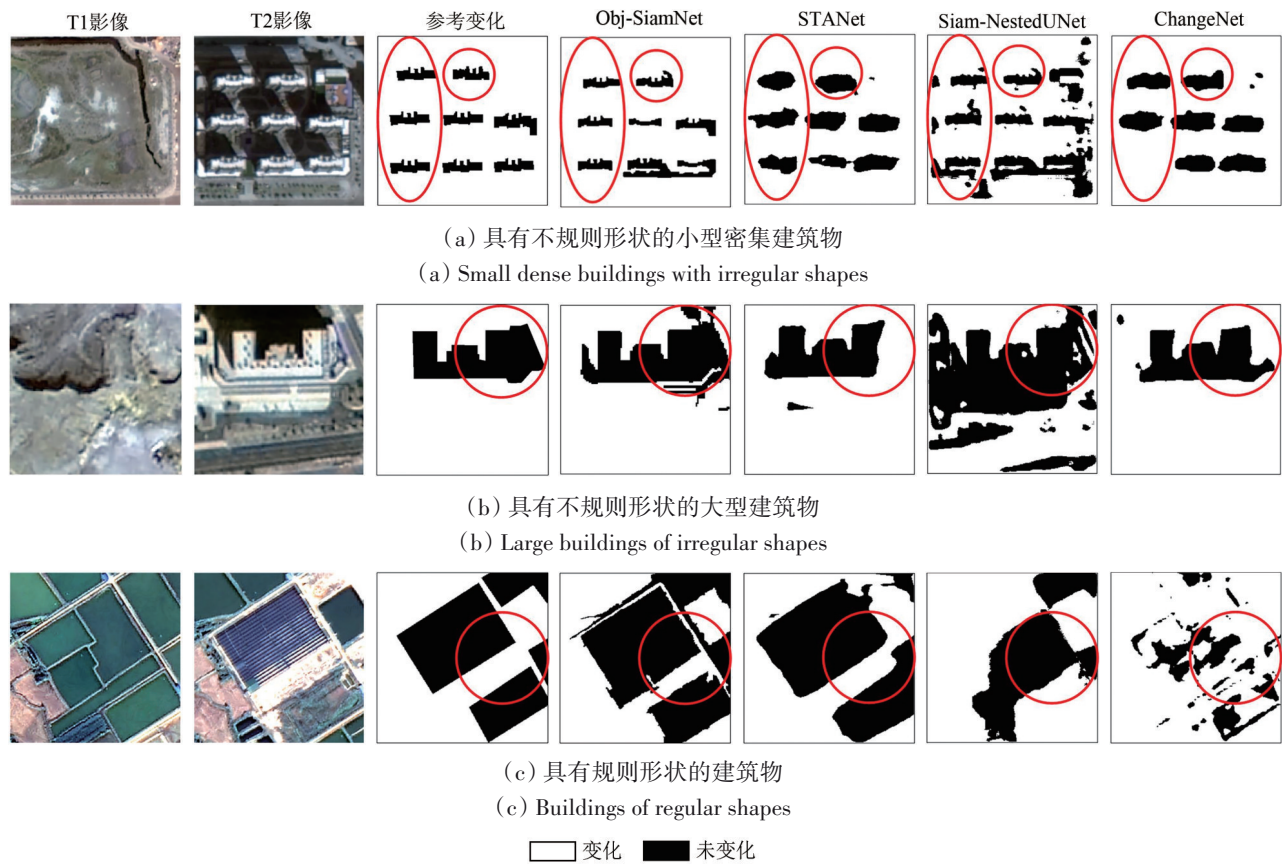


图 14 不同建筑物变化检测方法与本方法(Obj-SiamNet)在结果细节上的对比分析

Fig. 14 Comparative analysis of building change results: our method (i.e., Obj-SiamNet) vs. existing methods

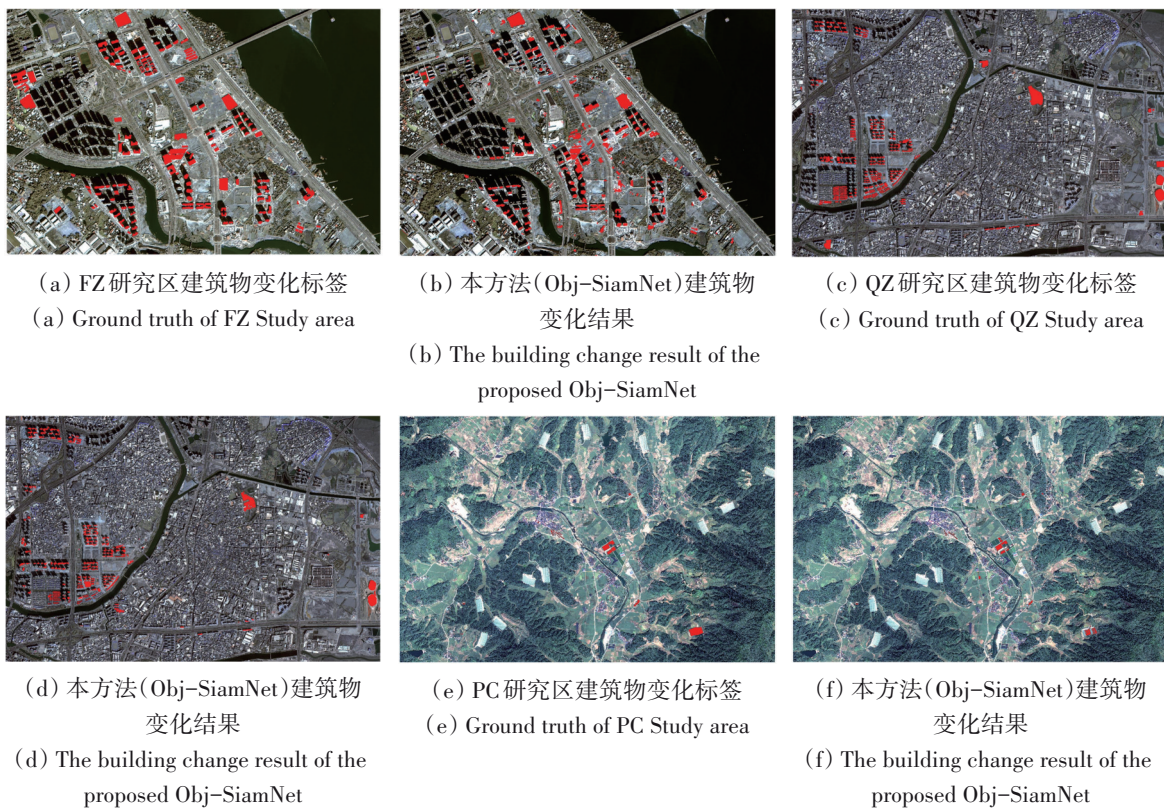


图 15 基于本方法 Obj-SiamNet 的 3 个研究区域建筑物变化检测结果

Fig. 15 Building change results obtained by the proposed Obj-SiamNet in three study areas

表5 基于本方法 Obj-SiamNet 的3个研究区域建筑物变化检测结果的精度评价表

Table 5 Accuracy evaluation of the building change results obtained by Obj-SiamNet in three study areas

研究区	F1 分数	精确率	召回率	全局总体误差	全局欠分误差	全局过分误差
FZ	73	69	77	19	18	16
QZ	78	74	83	20	13	23
PC	79	87	72	23	20	12

4 讨 论

本文提出一种基于面向对象孪生神经网络的高分辨影像建筑物变化检测方法，重点研究了利用面向对象分析技术提升经典孪生神经网络变化检测结果的几何精度，以及多尺度检测结果的自动融合方法。较 STANet、ChangeNet 和 Siam-NestedUNet 变化检测模型，本方法在处理检测结果边界锯齿化以及检测精度方面，具有明显的优越性；具体的，GTC 最高降低了9%，召回率最高提升32%，F1 指数提升23%。在福州、泉州和浦城3个实验区检测结果中，Obj-SiamNet 的召回率均可

达70%以上，F1 指数最高为79%。

本文使用多分辨率分割算法进行图像分割，在图像分割时，由于小型密集建筑群分割不精准（图16的区域A、图16的区域B）或将建筑物与其他地物分割为一个对象（图16的区域C），造成检测结果存在粘连现象，无法精确检测出实际变化边界，误检率和漏检率增加。且该分割算法需手动设置分割参数，所选参数可能无法适用于全部城市场景。进一步的研究可侧重在图像分割方法的选择上，或者分割参数优化上面，比如选择 ESP 分割工具（Drăguț 等，2010），进一步提升本方法的检测性能和适用性。

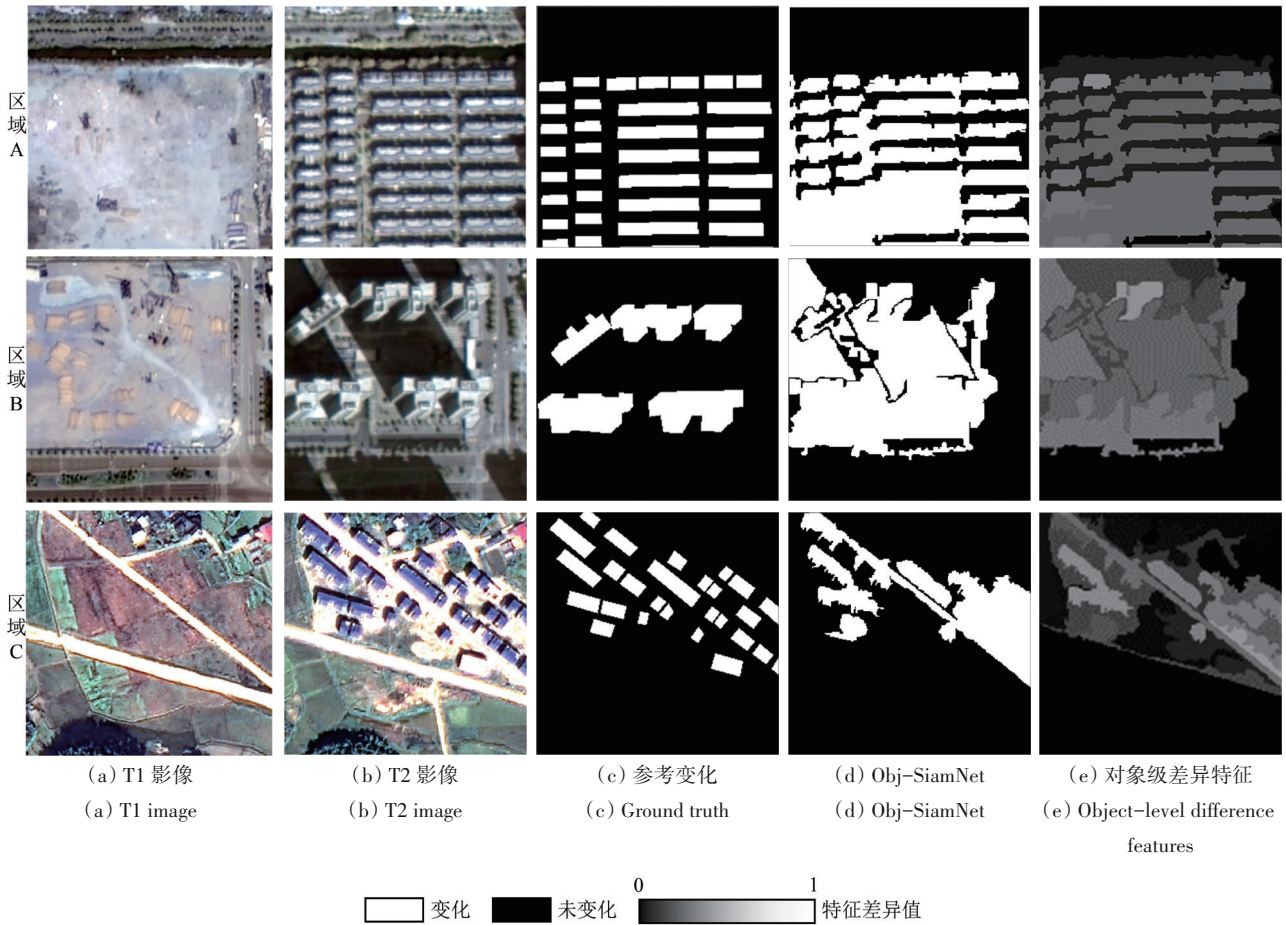


图16 Obj-SiamNet 获取的建筑物变化检测结果中存在粘连现象的实例

Fig. 16 Examples of building change results with adjacent buildings obtained by Obj-SiamNet

基于模糊集理论的多尺度检测结果自动融合方法, 避免了单一分割尺度检测结果造成的漏检误检问题。FZ-A 区域的多尺度融合结果相比于单一分割尺度检测结果更精准, 精确率最高提升 11%, 召回率较 3 个单一尺度检测结果均提升 25% 以上。

另外, 挑选研究区和仿研究区数据集中建筑物变化程度在 20%—80% 的样本来构建模型训练样本库。使用该规则筛选后的样本中, 变化程度在 20%—60% 的样本数量占了总样本量的 92.36%, 变化程度在 60%—80% 的样本数量仅占总量的 7% 左右, 这保证了模型的正负样本均衡, 该样本筛选规则具有合理性和可行性。未来, 可进一步完善对于变化程度过高或过低的样本取舍规则。

此外, 本文利用 Cycle GANs 进行样本迁移, 可将公开数据与研究区数据集相互转换, 且训练 Cycle GANs 的数据集不需要成对匹配, 提高了样本迁移效率。本研究使用空间分辨率为 0.5 m 的 CD_Data_GZ 数据集进行样本迁移, 在 FZ-A 研究区和 QZ-A 研究区的实验结果均证实了该迁移方法的有效性。QZ-A 研究区效果更显著, 所有精度评价指标均有较大提升, 召回率由 67% 提升至 83%, 精确率由 61% 提升至 74%。但使用该方法样本迁移时, 要求公开数据集与研究区数据集的空间分辨率相近, 对于空间分辨率相差较大的公开数据集, 可能无法实现有效迁移, 未来可进一步研究提升生成对抗网络样本迁移效率的策略。

5 结 论

本文提出一种基于面向对象孪生神经网络 (Obj-SiamNet) 和 Cycle GANs 样本迁移策略的高分辨率遥感影像建筑物变化检测方法, 有效提升了传统孪生神经网络获取的建筑物变化检测结果的几何精度, 降低了深度学习模型训练样本库构建成本。并应用本方法在 3 个研究区上进行了验证, 主要结论如下:

(1) 与 STANet、ChangeNet 和 Siam-Nest-edUNet 3 种现有模型相比, Obj-SiamNet 检测结果整体较优, 漏检现象改善明显, 召回率平均提升 26.3%, F1 平均提升 16.7%, 全局总体误差平均降低 7%, 证明了本方法的优越性。更进一步地, 使用 Obj-SiamNet 在福州、泉州、浦城 3 个不同实验区获得了成功应用, 全局总体误差最低为 19%, F1 分数最高为 79%, 召回率最高可达 83%, 验证了本方

法的适用性。

(2) 融合面向对象多尺度分割的检测结果较单一尺度分割的检测结果, 可减少影像信息损失, 提升检测结果精度, 召回率最高提升 32%, F1 分数最高提升 25%, 全局总体误差最高降低 7%。

(3) 使用 Cycle GANs 迁移样本, 增加了训练样本量, 进而提升了模型预测性能, 两个研究区的检测结果较未使用样本迁移的检测结果有明显提升, F1 分数最高提升 14%, GTC 降低 9%。在泉州研究区, 召回率由 67% 提升至 83%, 精确率由 61% 提升至 74%, F1 分数由 64% 提升至 78%, 全局总体误差由 29% 降低至 20%。

Obj-SiamNet 方法对于其他地物变化检测同样具有借鉴意义。后续研究可侧重在影像分割方法的选择以及孪生神经网络主干网络的设计上。此外, 也可增加多种样本类型, 在土地利用层面进行语义变化检测研究。

参考文献 (References)

- Benz U C, Hofmann P, Willhauck G, Lingenfelder I and Heynen M. 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3/4): 239-258 [DOI: 10.1016/j.isprsjprs.2003.10.002]
- Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2-16 [DOI: 10.1016/j.isprsjprs.2009.06.004]
- Chen H and Shi Z W. 2020. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. *Remote Sensing*, 12(10): 1662-1684 [DOI: 10.3390/rs12101662]
- Chen J, He C Y, Shi P J, Chen Y H and Ma N. 2001. Land use/cover change detection with change vector analysis (CVA): change magnitude threshold determination. *Journal of Remote Sensing*, 5(4): 259-266 (陈晋, 何春阳, 史培军, 陈云浩, 马楠. 2001. 基于变化向量分析的土地利用/覆盖变化动态监测(I)——变化阈值的确定方法. *遥感学报*, 5(4): 259-266) [DOI: 10.11834/jrs.20010404]
- Chopra S, Hadsell R and LeCun Y. 2005. Learning a similarity metric discriminatively, with application to face verification//*Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Diego, CA, USA: IEEE: 539-546 [DOI: 10.1109/CVPR.2005.202]
- Coulter L L, Stow D A, Tsai Y H, Ibanez N, Shih H C, Kerr A, Benza M, Weeks J R and Mensah F. 2016. Classification and assessment of land cover and land use change in southern Ghana using dense stacks of Landsat 7 ETM+imagery. *Remote Sensing of Environ-*

- ment, 184: 396-409 [DOI: 10.1016/j.rse.2016.07.016]
- Desclée B, Bogaert P and Defourny P. 2006. Forest change detection by statistical object-based method. *Remote Sensing of Environment*, 102(1/2): 1-11 [DOI: 10.1016/j.rse.2006.01.013]
- Drăguț L, Tiede D and Levick S R. 2010. ESP: a tool to estimate scale parameter for multi-resolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*, 24(6): 859-871 [DOI: 10.1080/13658810903174803]
- Feng W Q and Zhang Y J. 2015. Object-oriented change detection for remote sensing images based on multi-scale fusion. *Acta Geodaetica et Cartographica Sinica*, 44(10): 1142-1151 (冯文卿, 张永军. 2015. 利用多尺度融合进行面向对象的遥感影像变化检测. *测绘学报*, 44(10): 1142-1151) [DOI: 10.11947/j. AGCS2.0152. 0140260]
- Goodfellow I J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A and Bengio Y. 2014. Generative adversarial nets//*Proceedings in Neural Information Processing Systems*. Montreal: MIT Press: 2672-2680 [DOI: 10.48550/arXiv. 1406. 2661]
- Hadsell R, Chopra S and LeCun Y. 2006. Dimensionality reduction by learning an invariant mapping//*Proceedings of 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. New York, NY, USA: IEEE: 1735-1742 [DOI: 10.1109/CVPR.2006.100]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Huang B, Zhao B and Song Y M. 2018a. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery. *Remote Sensing of Environment*, 214: 73-86 [DOI: 10.1016/j.rse.2018.04.050]
- Huang F M, Chen L X, Yin K L, Huang J S and Gui L. 2018b. Object-oriented change detection and damage assessment using high-resolution remote sensing images, Tangjiao Landslide, Three Gorges Reservoir, China. *Environmental Earth Sciences*, 77(183) [DOI: 10.1007/s12665-018-7334-5]
- Huang P, Zheng Q and Liang C. 2020. Overview of image segmentation methods. *Journal of Wuhan University (Natural Science Edition)*, 66(6): 519-531 (黄鹏, 郑淇, 梁超. 2020. 图像分割方法综述. *武汉大学学报(理学版)*, 66(6): 519-531) [DOI: 10.14188/j. 1671-8836.2019.0002]
- Isola P, Zhu J Y, Zhou T H and Efros A A. 2017. Image-to-image translation with conditional adversarial networks//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE: 5967-5976 [DOI: 10.1109/CVPR.2017.632]
- Karras T, Aila T, Laine S and Lehtinen J. 2018. Progressive growing of GANs for improved quality, stability, and variation. *Proceedings of 2018 International Conference on Learning Representations*. [DOI: 10.48550/arXiv.1710.10196]
- Khelifi L and Mignotte M. 2020. Deep learning for change detection in remote sensing images: comprehensive review and meta-analysis. *IEEE Access*, 8: 126385-126400 [DOI: 10.1109/ACCESS.2020. 3008036]
- Kingma P D and Ba L J. 2015. Adam: a method for stochastic optimization//*Proceedings of 2015 International Conference on Learning Representations*. San Diego. [DOI: 10.48550/arXiv.1412.6980]
- Li K Y, Li Z, and Fang S. 2021. Siamese NestedUNet Networks for Change Detection of High Resolution Satellite Image//*Proceedings of 2020 1st International Conference on Control, Robotics and Intelligent System*. Association for Computing Machinery, New York, NY, USA: IEEE: 42-48 [DOI: 10.1145/3437802.3437810]
- Li M M, Bijker W and Stein A. 2015. Use of Binary Partition Tree and energy minimization for object-based classification of urban land cover. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102: 48-61 [DOI: 10.1016/j.isprsjprs.2014.12.023]
- Li M M, Stein A, Bijker W and Zhan Q M. 2016. Region-based urban road extraction from VHR satellite images using Binary Partition Tree. *International Journal of Applied Earth Observation and Geo-information*, 44: 217-225 [DOI: 10.1016/j.jag.2015.09.005]
- Liu S C, Du P J and Chen S J. 2011. A novel change detection method of multi-resolution remotely sensed images based on the decision level fusion. *Journal of Remote Sensing*, 15(4): 846-862 (柳思聪, 杜培军, 陈绍杰. 2011. 决策级融合的多分辨率遥感影像变化检测. *遥感学报*, 15(4): 846-862) [DOI: 10.11834/jrs.20110098]
- Liu T, Yang L X and Lunga D. 2021. Change detection using deep learning approach with object-based image analysis. *Remote Sensing of Environment*, 256: 112308-112323 [DOI: 10.1016/j.rse.2021.112308]
- Nair V and Hinton G E. 2010. Rectified linear units improve restricted Boltzmann machines//*Proceedings of the 27th International Conference on International Conference on Machine Learning*. Haifa: Omnipress: 807-814 [DOI: 10.1.1.165.6419/arXiv: 1111.6189v1]
- Otsu N. 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9 (1): 62-66 [DOI: 10.1109/TSMC.1979.4310076]
- Paul S, Saxena K G, Nagendra H and Lele N. 2021. Tracing land use and land cover change in peri-urban Delhi, India, over 1973-2017 period. *Environmental Monitoring and Assessment*, 193(52) [DOI: 10.1007/s10661-020-08841-x]
- Peng D F, Bruzzone L, Zhang Y J, Guan H Y, Ding H Y and Huang X. 2021. SemiCDNet: a semisupervised convolutional neural network for change detection in high resolution remote-sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 59(7): 5891-5906 [DOI: 10.1109/TGRS.2020.3011913]
- Radford A, Metz L and Chintala S. 2016. Unsupervised representation learning with deep convolutional generative adversarial networks. [DOI: 10.48550/arXiv.1511.06434]
- Shen Y, Wang H, Dai Y X. 2018. Deep siamese network-based classifier and its application. *Computer Engineering and Applications*, 54

- (10): 19-25 (沈雁,王环,戴瑜兴. 基于改进深度孪生网络的分类器及其应用[J]. 计算机工程与应用,2018,54(10):19-25) [DOI: CNKI:SUN:JSGG.0.2018-10-003]
- Sui H G, Feng W Q, Li W Z, Sun K M and Xu C. 2018. Review of change detection methods for multi-temporal remote sensing imagery. *Geomatics and Information Science of Wuhan University*, 43(12): 1885-1898 (桂海刚, 冯文卿, 李文卓, 孙开敏, 徐川. 2018. 多时相遥感影像变化检测方法综述. 武汉大学学报(信息科学版), 43(12): 1885-1898) [DOI: 10.13203/j.whugis20180251]
- Sun X X, Zhang J X, Yan Q and Gao J X. 2011. A summary on current techniques and prospects of remote sensing change detection. *Remote Sensing Information*, (1): 119-123 (孙晓霞, 张继贤, 燕琴, 高井祥. 2011. 遥感影像变化检测方法综述及展望. 遥感信息, (1): 119-123) [DOI: 10.3969/j.issn.1000-3177.2011.01.023]
- Tang Z X, Li M M and Wang X Q. 2020. Mapping tea plantations from VHR images using OBIA and convolutional neural networks. *Remote Sensing*, 12(18): 2935-2953 [DOI: 10.3390/rs12182935]
- Tobias O J and Seara R. 2002. Image segmentation by histogram thresholding using fuzzy sets. *IEEE Transactions on Image Processing*, 11(12): 1457-1465 [DOI: 10.1109/TIP.2002.806231]
- Tong G F, Li Y, Ding W L and Yue X Y. 2015. Review of remote sensing image change detection. *Journal of Image and Graphics*, 20(12): 1561-1571 (佟国峰, 李勇, 丁伟利, 岳晓阳. 2015. 遥感影像变化检测算法综述. 中国图象图形学报, 20(12): 1561-1571) [DOI: 10.11834/Jig.20151201]
- Varghese A, Gubbi J, Ramaswamy A and Balamuralidhar P. 2019. ChangeNet: a deep learning architecture for visual change detection//*Proceedings of 2018 European Conference on Computer Vision Workshops*. Munich, Germany: Springer: 129-145 [DOI: 10.1007/978-3-030-11012-3_10]
- Wang J, Xiao X M, Liu L, Wu X C, Qin Y W, Steiner J L and Dong J W. 2020. Mapping sugarcane plantation dynamics in Guangxi, China, by time series Sentinel-1, Sentinel-2 and Landsat images. *Remote Sensing of Environment*, 247: 111951-111966 [DOI: 10.1016/j.rse.2020.111951]
- Wang Y L, Pu J, Zhao J H and Li J H. 2019. Detection of new ground buildings based on generative adversarial network. *Journal of Computer Applications*, 39(5): 1518-1522 (王玉龙, 蒲军, 赵江华, 黎建辉. 2019. 基于生成对抗网络的地面新增建筑检测. 计算机应用, 39(5): 1518-1522) [DOI: 10.11772/j.issn.1001-9081.2018102083]
- Wen D W, Huang X, Bovolo F, Li J Y, Ke X L, Zhang A L and Benediktsson J A. 2021. Change detection from very-high-spatial-resolution optical remote sensing images: methods, applications, and future directions. *IEEE Geoscience and Remote Sensing Magazine*, 9(4): 68-101 [DOI: 10.1109/MGRS.2021.3063465]
- Wen D W, Huang X, Zhang A L and Ke X L. 2019. Monitoring 3D building change and urban redevelopment patterns in Inner City Areas of Chinese megacities using multi-view satellite imagery. *Remote Sensing*, 11(7): 763-785 [DOI: 10.3390/rs11070763]
- Woo S, Park J, Lee J Y and Kweon I S. 2018. CBAM: convolutional block attention module//*Proceedings of 2018 European Conference on Computer Vision*. Munich, Germany: Springer: 3-19 [DOI: 10.1007/978-3-030-01234-2_1]
- Xu Y D, Yu L, Zhao F R, Cai X L, Zhao J Y, Lu H and Gong P. 2018. Tracking annual cropland changes from 1984 to 2016 using time-series Landsat images with a change-detection and post-classification approach: experiments from three sites in Africa. *Remote Sensing of Environment*, 218: 13-31 [DOI: 10.1016/j.rse.2018.09.008]
- Yang K P, Xia G S, Liu Z C, Du B, Yang W, Pelillo M and Zhang L P. 2022. Asymmetric Siamese networks for semantic change detection in aerial images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5609818-5609835 [DOI: 10.1109/TGRS.2021.3113912]
- Zabalza J, Ren J C, Zheng J B, Zhao H M, Qing C M, Yang Z J, Du P J and Marshall S. 2016. Novel segmented stacked autoencoder for effective dimensionality reduction and feature extraction in hyperspectral imaging. *Neurocomputing*, 185: 1-10 [DOI: 10.1016/j.neucom.2015.11.044]
- Zhang C, Sargent I, Pan X, Li H P, Gardiner A, Hare J and Atkinson P M. 2018. An object-based convolutional neural network (OCNN) for urban land use classification. *Remote Sensing of Environment*, 216: 57-70 [DOI: 10.1016/j.rse.2018.06.034]
- Zhang Z C, Vosselman G, Gerke M, Persello C, Tuia D and Yang M Y. 2019. Detecting building changes between airborne laser scanning and photogrammetric data. *Remote Sensing*, 11(20): 2417-2433 [DOI: 10.3390/rs11202417]
- Zhou Q M. 2011. Review on change detection using multi-temporal remotely sensed imagery. *Geomatics World*, 9(2): 28-33 (周启鸣. 2011. 多时相遥感影像变化检测综述. 地理信息世界, 9(2): 28-33) [DOI: 10.3969/j.issn.1672-1586.2011.02.007]
- Zhu J Y, Park T, Isola P and Efros A A. 2017. Unpaired image-to-image translation using cycle-consistent adversarial networks//*Proceedings of 2017 IEEE International Conference on Computer Vision*. Venice, Italy: IEEE: 2242-2251 [DOI: 10.1109/ICCV.2017.244]
- Zhu Q Q, Guo X, Deng W H, Shi S N, Guan Q F, Zhong Y F, Zhang L P and Li D R. 2022. Land-Use/Land-Cover change detection based on a Siamese global learning framework for high spatial resolution remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 184: 63-78 [DOI: 10.1016/j.isprsjrs.2021.12.005]

Use of object-based Siamese neural network to build change detection from very high resolution remote-sensing images

LIU Xuanguang^{1,2}, LI Mengmeng^{1,2}, WANG Xiaoqin^{1,2}, ZHANG Zhenchao³

1. Academy of Digital China (Fujian), Fuzhou University, Fuzhou 350108, China;

2. Key Laboratory of Spatial Data Mining and Information Sharing of Ministry of Education, Fuzhou University, Fuzhou 350108, China;

3. Institute of Geospatial Information, Information Engineering University, Zhengzhou 450001, China

Abstract: Building change detection is essential to many applications, such as monitoring of urban areas, land use management, and illegal building detection. It has been seen as an effective means to detect building changes from remote-sensing images.

This paper proposes an object-based Siamese neural network, labeled as Obj-SiamNet, to detect building changes from high-resolution remote-sensing images. We combine the advantages of object-based image analysis methods and Siamese neural networks to improve the geometric accuracies of detected boundaries. Moreover, we implement the Obj-SiamNet at multiple segmentation levels and automatically construct a set of fuzzy measures to fuse the obtained results at multi-levels. Furthermore, we use generative adversarial methods to generate target-like training samples from publicly available datasets and construct a relatively sufficient training dataset for the Obj-SiamNet model. Finally, we apply the proposed method into three high-resolution remote-sensing datasets, i.e., a GF-2 image-pair in Fuzhou City, and a GF2 image pair in Pucheng County, and a GF-2—GF-7 image pair in Quanzhou City. We also compare the proposed method with three other existing ones, namely, STANet, ChangeNet, and Siam-NestedUNet.

Experimental results show that the proposed method performs better than the other three in terms of detection accuracy. (1) Compared with the detection results from single-scale segmentation, the detection results from multi-scale increases the recall rate by up to 32%, the F1-Score increases by up to 25%, and the Global Total Classification error (GTC) decreases by up to 7%. (2) When the number of available samples is limited, the adopted Generative Adversarial Network (GAN) is able to generate effective target-like samples for diverting samples. Compared with the detection without using GAN-generated samples, the proposed detection increases the recall rate by up to 16%, increases the F1-Score by up to 14%, and decreases GTC by 9%. (3) Compared with other change-detection methods, the proposed method improves the detection accuracies significantly, i.e., the F1-Score increases by up to 23%, and GTC decreases by up to 9%. Moreover, the boundaries of the detected changes by the proposed method have a high consistency with that of ground truth.

We conclude that the proposed Obj-SiamNet method has a high potential for building change detection from high-resolution remote-sensing images.

Key words: change detection of remote sensing, Siamese Neural Network, object-based multi-scale analysis, fuzzy sets fusion, generative adversarial network, very high resolution remote sensing images

Supported by National Natural Science Foundation of China (No. 42001283); Natural Science Foundation of Fujian Province, China (No. 2021J01630)