

# 基于深度学习的高分辨率遥感图像建筑物变化检测

韩星<sup>1</sup>, 韩玲<sup>2,3\*</sup>, 李良志<sup>1</sup>, 李慧慧<sup>1</sup>

<sup>1</sup>长安大学地质工程与测绘学院, 陕西 西安 710054;

<sup>2</sup>长安大学土地工程学院, 陕西 西安 710054;

<sup>3</sup>陕西省土地整治重点实验室, 陕西 西安 710054

**摘要** 针对传统语义分割网络检测精度低, 对中、小尺度目标存在误检漏检, 对边界分割粗糙等现象, 提出了一种基于深度学习的高分辨率遥感图像建筑物变化检测方法。采用编码-解码结构, 在编码阶段采用残差网络提取图像特征, 并为编码器最深层特征引入空洞卷积和金字塔池化模块, 增大感受野以提取多尺度图像特征; 在解码阶段使用注意力模块突出有用特征, 接着聚合不同尺度不同分辨率的特征。在大型遥感建筑物变化检测数据集上进行实验。结果表明, 所提方法在获取深层语义信息的同时可以较好地关注到细节信息, 在精确率、召回率、F1 分数上均有明显提升, 在多尺度目标检测、建筑物边界提取等方面优于其他常用的语义分割网络。

**关键词** 遥感影像; 变化检测; ResNet50; 注意力机制; 特征金字塔

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP202259.1001003

## Building Change Detection in High-Resolution Remote-Sensing Images Based on Deep Learning

Han Xing<sup>1</sup>, Han Ling<sup>2,3\*</sup>, Li Liangzhi<sup>1</sup>, Li Huihui<sup>1</sup>

<sup>1</sup>School of Geology Engineering and Geomatics, Chang'an University, Xi'an 710054, Shaanxi, China;

<sup>2</sup>School of Land Engineering, Chang'an University, Xi'an 710054, Shaanxi, China;

<sup>3</sup>Shaanxi Key Laboratory of Land Consolidation, Xi'an 710054, Shaanxi, China

**Abstract** To overcome low detection accuracy, false and leak detections for medium- and small-scale targets, rough segmentation for building boundary of traditional semantic segmentation network, we propose a high-resolution remote-sensing image building change detection method based on deep learning. The proposed method adopts the coding-decoding structure. At the coding stage, the residual network is used to extract the image features. The dilated convolution and pyramid pooling module are introduced in the deepest features of the encoder to enlarge the receptive field and extract the multiscale image features. At the decoding stage, the attention module highlights the useful features, and the features with different scales and resolutions are aggregated. We performed experiments on large-scale remote-sensing building change detection datasets. The results show that the proposed method can obtain deep-layer semantic information and pay attention to detailed information. It also has a considerable improvement in precision, recall, and F1 score. Additionally, the proposed method performs better than other semantic segmentation networks in multiscale target detection and building boundary extraction.

**Key words** remote sensing image; change detection; ResNet50; attention mechanism; feature pyramid

收稿日期: 2021-06-09; 修回日期: 2021-08-07; 录用日期: 2021-08-17

基金项目: 国家科技重大专项(211735210034)、装备预研教育部联合基金(6141A02022376)

通信作者: hanling@chd.edu.cn

## 1 引言

遥感变化检测 (remote sensing change detection) 是识别多时相遥感影像<sup>[1]</sup>之间显著差异的过程, 针对高分辨率遥感影像建筑物变化检测的应用广泛, 如城镇化监测、土地利用变化检测、灾害评价和环境监测<sup>[2-6]</sup>等。近年来, 随着对地观测技术的快速发展, 大量高分辨率光学遥感卫星的发射给遥感图像处理带来了新的机遇和挑战。在城市化进程快速发展的今天, 有大量的建筑物存在新建、扩张、违建、改建、拆除的现象, 人工实地调研、调查取证的方法虽然精度较高, 但无法做到实时和全方位监管, 并且工作过于繁琐, 耗费大量的人力物力财力, 无法满足当前智能时代的基本要求。

传统的遥感图像变化检测方法<sup>[7]</sup>一般分为三步。首先, 为了消除各种原因带来的图像差异, 对图像进行配准、去噪等操作; 接着, 通过图像差值、图像比值来生成两时相的差分变化图像; 最后, 根据该图像提取变化特征, 分析得到变化图。王丽涛等<sup>[8]</sup>通过分析纹理参数, 基于贝叶斯图像阈值分割技术, 通过分析汶川地震前后遥感影像建立基于纹理信息的高分辨率变化检测方法。辛芳芳等<sup>[9]</sup>将双高斯变化模型同小波变化相结合, 引入马尔可夫模型, 根据连续最大后验概率, 得到变化检测结果图, 使单函数匹配率低的问题得到了有效解决。施向丰等<sup>[10]</sup>首先对影像进行特征提取, 通过计算差值、确定阈值、检测空间滤波等方法, 选出感兴趣区域, 获得变化监测结果。以上特征表示方法依赖手工构建, 无法对高层次的变化信息进行有效建模, 当需要分类的两类别特征重叠时, 检测结果会产生误差。

近年来, 随着深度学习技术的迅猛发展, 其在目标检测、语义分割及图像分类等多领域取得了不错的成绩, 多数学者开始关注其在遥感图像变化检测中的应用<sup>[11-13]</sup>。为了增强卷积神经网络(CNN)的表达能力, Woo等<sup>[14]</sup>基于注意力机制提出通道注意力模块和空间注意力模块, 并将它们嵌入CNN中, 该方法在ImageNet数据集上取得了不错的效果。张翠军等<sup>[15]</sup>针对图像背景复杂、小目标容易被漏检的问题, 在UNet模型中引入注意力机制, 在特征提取部分用非对称卷积块来代替标准卷积操作, 结果表明F1分数有明显提升。随着空间池化金字塔模

块和空洞卷积(dilated convolution)等方法的提出及应用, 通过更多地获取多尺度信息和上下文信息, 这些方法在遥感影像分割中有不错的效果。胡蕾等<sup>[16]</sup>针对变化检测对小目标检测不明显的问题, 提出一种多尺度稀疏卷积变化检测方法, 该方法将相关性高、同一位置的特征聚合在一起, 有效解决了大目标和小目标的变化检测问题。陈璐等<sup>[17]</sup>将不同的语义分割模型应用到遥感图像变化检测中, 发现预处理后模型精度得到有效提升。向阳等<sup>[18]</sup>为了解决大量人工提取特征的问题, 提出改进的UNet孪生网络结构, 嵌入特征金字塔模块, 将中心环绕区域输入网络的孪生结构编码端, 检测效果明显提高。张哲晗等<sup>[19]</sup>针对农用地检测问题, 提出一种改进的编码-解码网络结构, 并对其分割结果与经典语义分割网络的分割结果进行对比, 证明了该网络的有效性。

受上述研究启发, 本文致力于研究如何提取并融合不同层次建筑物特征, 解决建筑物边界捕捉模糊、小尺度目标漏检和误检等问题, 提出了一种基于深度学习的高分辨率遥感图像建筑物变化检测方法。采用编码-解码的网络结构, 编码阶段使用残差网络提取图像特征, 在编码器的最深特征层引入空洞卷积和金字塔池化模块; 解码阶段, 逐级引用注意力模块以关注重要特征, 接着聚合高、低层特征, 增强网络的特征提取能力。在大型遥感变化检测数据集上测试了所提网络的性能, 并与其他常用的变化检测网络作对比。

## 2 所提方法内容

### 2.1 注意力机制

为了在复杂的信息中更好地关注感兴趣的内容, 人们开始关注注意力机制。卷积模块的注意力机制模块(CBAM)<sup>[14]</sup>是一种结合了空间和通道的注意力机制模块, 结构如图1所示, 包含两个独立的子模块, 分别是通道注意力模块(channel attention module)和空间注意力模块(spatial attention module)。两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。通过增大图像特征的权重, 来关注重要的特征, 抑制不必要的特征。引入CBAM, 使网络能够更好地区分特征之间的重要程度, 从而聚焦有用特征。

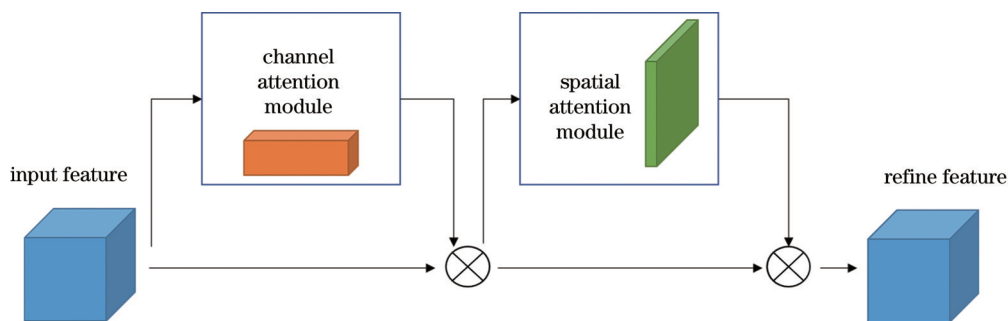


图1 CBAM结构

Fig. 1 CBAM structure

### 2.2 空间金字塔池化模块

在语义分割中如果未能充分利用上下文信息,会导致在不同尺度的物体分割上效果差<sup>[20]</sup>。传统的池化操作在某个固定尺寸下进行下采样,无法充分利用图像全局信息,对不同尺寸建筑物分割效果差。空间池化金字塔模块(PPM)<sup>[21]</sup>可以有效解决

这一问题,该模块起初是在金字塔场景解析网络模型PSPNet中提出的,是一种特殊的池化机制,通过由多到少的池化增大感受野,进而有效利用全局信息,结构如图2所示。在编码阶段引入PPM,来增大感受野,充分利用图像的全局信息,从而提高对图像的分割精度。




图2 PPM结构

Fig. 2 PPM structure

### 2.3 所提方法结构

所提网络结构分为编码与解码两个部分。在编码阶段,首先使用ResNet50网络进行特征提取,如图3所示,将残差网络结构分为5个阶段,包括Conv1、Conv2、Conv3、Conv4、Conv5,分别对应输出特征图的大小为 $112 \times 112$ 、 $56 \times 56$ 、 $28 \times 28$ 、 $14 \times 14$ 、 $7 \times 7$ 。为了弥补视野缺失,更好地增强网络对图像空间信息的获取,减少对建筑物的漏检现象,增大网络的感受野,在残差网络最深层特征阶段使用扩张率为2的空洞卷积来代替普通卷积,如图3所示,对应输出特征图的尺寸分别为 $112 \times 112$ 、 $56 \times 56$ 、 $28 \times 28$ 、 $14 \times 14$ 、 $14 \times 14$ 。编码阶段的网络

结构和输出特征图尺寸如表1所示。此外,为了优化分割结果,更好地获取上下文信息,减少目标物的漏检、误检现象,在空洞卷积之后,对编码器最深特征层 $F_5$ 进行空间金字塔池化操作,得到特征图 $F'_5$ 。

$$S_1 = F_c(f), \quad (1)$$

式中: $F_c(\cdot)$ 表示CBAM操作; $f$ 表示图像逐级特征。

$$S_2 = F_p(f_5), \quad (2)$$

式中: $F_p(\cdot)$ 表示PPM操作; $f_5$ 表示编码阶段图像第五层特征。

$$R = S[C(S_1, S_2)], \quad (3)$$

式中: $S$ 表示sigmoid函数; $C$ 表示concatenate聚合

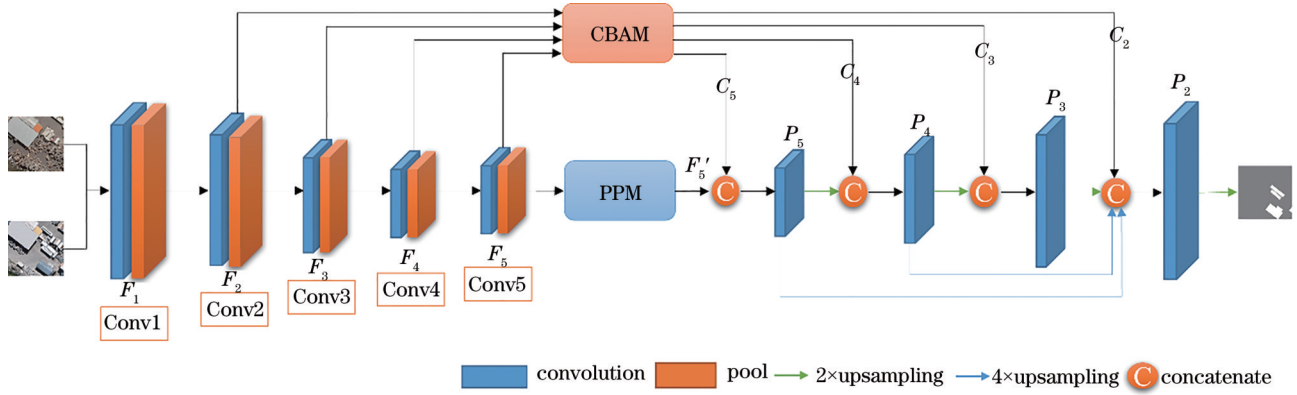


图 3 所提网络结构

Fig. 3 Proposed network structure

表 1 特征提取阶段网络结构

Table 1 Network structure of feature extraction stage

ResNet50	Size
$7 \times 7, 64, \text{stride}2$	$112 \times 112$
$3 \times 3, \text{max pooling, stride}2$	
$\begin{bmatrix} 1 \times 1 & 64 \\ 3 \times 3 & 64 \\ 1 \times 1 & 256 \end{bmatrix} \times 3$	$56 \times 56$
$\begin{bmatrix} 1 \times 1 & 128 \\ 3 \times 3 & 128 \\ 1 \times 1 & 514 \end{bmatrix} \times 4$	$28 \times 28$
$\begin{bmatrix} 1 \times 1 & 256 \\ 3 \times 3 & 256 \\ 1 \times 1 & 1024 \end{bmatrix} \times 6$	$14 \times 14$
$\begin{bmatrix} 1 \times 1 & 512 \\ 3 \times 3 & 512 \\ 1 \times 1 & 2048 \end{bmatrix} \times 3$	$14 \times 14$
(dilated convolution)	

操作;  $R$  表示变化检测结果。

研究结果<sup>[17]</sup>表明,高层特征编码了丰富的上下文和全局信息,但丢失了精细的空间信息,而低层特征则相反。因此在解码部分,为了有效融合高层语义信息和低层空间信息,首先将每一个残差块生成的特征图  $F_2, F_3, F_4, F_5$  分别输入注意力模块,生成逐级加强的  $C_2, C_3, C_4, C_5$ ; 随后,将特征图  $F_5'$  与  $C_5$  叠加,通过  $1 \times 1$  的卷积降维后得到特征图  $P_5$ , 再与特征图  $C_4$  叠加,逐级计算得到特征图  $P_4$  和  $P_3$ , 具体计算方法如图 3 所示。关于特征  $P_2$  的计算,如图 4 所示,对不同层次的特征图  $P_3, P_4, P_5$  分别进行上采样后,将结果图融合; 再与  $F_2$  经注意力机制后得到的特征图  $C_2$  进行融合, 经过卷积降维后得到特征图  $P_2$ , 该特征图包含不同尺度、不同语义强度的信息; 最后对特征图  $P_2$  上采样后输入分类器, 得到最终的变化检测结果图。

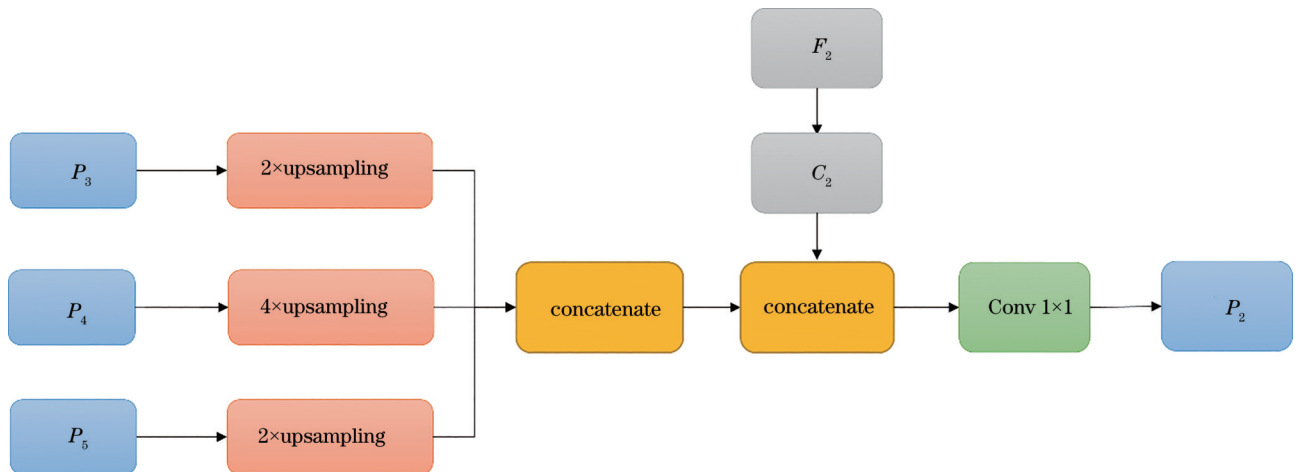


图 4 多尺度特征融合

Fig. 4 Multiscale feature fusion

### 3 实验数据及处理

#### 3.1 数据集

本实验所用数据集 WHU building dataset<sup>[22]</sup>来自武汉大学季顺平教授团队于 2012 年 4 月获取的新西兰 Christchurch 市的 12796 个建筑物以及 2016 年相同地区获取的 16077 个建筑物的大场景、高分辨率遥感数据集。其包含两个航拍图像和真实变化的标签图像,尺寸大小为 15354 pixel×32507 pixel,共 20.5 km<sup>2</sup>,地面分辨率为 0.075 m,配准精度为 1.6 pixel。

#### 3.2 数据预处理

数据集的两个时相航拍影像以及地面真实变化的标签图像大小均为 15354×32507,由于内

存限制,图像尺寸过大无法直接送入网络进行训练。为了保证顺利进行实验,对数据进行以下操作:

- 1) 以随机窗口的方式将两时相遥感图像和标签图像无重叠滑动裁剪为 256 pixel×256 pixel 大小的小尺寸遥感图像;
- 2) 将数据集按照 7:1:2 划分为无重叠的训练集、验证集、测试集三个部分;
- 3) 对数据集进行数据增强处理,包括对数据集进行旋转、翻转等操作。

#### 3.3 实验过程

本研究采用在 Ubuntu 下搭建的 Pytorch1.6 深度学习框架,GPU 的处理环境是 CUDA 10.0 和 CUDNN 7.6,具体信息如表 2 所示。

表 2 实验环境  
Table 2 Lab environment

Lab environment	Configuration
CPU	6×Intel(R)Xeon(R)CPU E5-2678 v3@2.50 GHz
GPU	NVIDIA GeForce RTX 2080 Ti
Memory	62 GB
Operating system	Ubuntu 18.04
Deep learning framework	Pytorch1.6
Programming language	Python 3.7
GPU processing framework	CUDA 10.0, CUDNN 7.6

网络配置方面,损失函数采用经典的二分类交叉熵损失函数,优化器采用 Adam 作为梯度下降方法,引入模拟退火算法调整学习率,使模型更好收敛。将 ReLU 函数作为激活函数,经过多次实验,将初始学习率设置为 0.001,每个批次的训练样本设置为 8 个,epoch 设置为 200。

对初始学习率与迭代次数进行优化。使用自适应学习方式优化,使用 F1 度量作为网络的效果评估。先使用固定 500 次的最大迭代优化初始学习速率,由表 3 可知,初始学习速率为 0.0001 时,网络的结果最好,因此选定 0.0001 作为初始学习速率。再固定学习率,调试最大迭代次数,当迭代次数为 200 时,网络的效果开始趋于稳定。所以,超参数的最终优化结果为初始学习率 0.0001,最大迭代次数 200。

#### 3.4 实验评价指标

所使用的评价标准为精确率 (precision)、召回率 (recall) 以及 F1 分数。精确率指的是所有被判定为正类中,真实的正类所占的比例,计算公式为

表 3 神经网络超参数优化

Table 3 Hyperparameters' optimization of neural network

Initial learning rate	Maximum number of iterations	F1/%
0.1		69.76
0.01		80.01
0.001	500	88.89
0.0001		90.38
0.00001		88.17
	50	85.64
	100	88.58
0.0001	200	90.17
	500	90.12

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

召回率表示在实际为正的样本中被预测为正确的比例,计算公式为

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

F1 值同时考虑精确率和召回率,是精确率和召

回率的调和平均值,综合考虑了两者的关系,且值越大,说明实验方法越有效,计算公式为

$$F_1 = \frac{2N_{TP}}{2N_{TP} + N_{FP} + N_{FN}}, \quad (6)$$

式中:TP表示本来是正样本,分类结果也是正样本;TN表示本来是负样本,分类结果也是负样本;FN表示本来是负样本,分类结果为正样本;FP表示本来是正样本,分类结果是负样本。

## 4 实验结果及分析

### 4.1 消融实验

将删除CBAM和PPM的网络称为基线网络。首先,对基线网络进行训练,得到了满意的结果。接着,经过实验发现,上述模块能够提高网络性能,表4显示了实验结果,加入CBAM后的网络对大范围的建筑物变化检测结果有显著改善,因为该模块通过对特征筛选加权,突出了同建筑物相关的显著特征而舍弃了一些无用特征,从而使得检测结果有所改善。加入PPM后,由于网络通过由多到少的池化,有效地增大了网络的感受野,更好地利用了影像的全局信息。同时引入CBAM和PPM,显著提高了网络对建筑物变化检测精度,有效改善了建筑物边界捕捉模糊、小尺度目标漏检和误检等现象,证明了模块的有效性。

表4 消融实验

Table 4 Ablation experiment

Method	Precision / %	Recall / %	F1 / %
Baseline	80.362	82.946	81.273
+CBAM	81.261	84.594	82.884
+PPM	80.567	83.339	81.460
Proposed method	82.508	85.232	83.324

### 4.2 与其他方法比较

为了验证所提网络的效果,将其变化检测结果同三种经典的语义分割模型UNet<sup>[23]</sup>、ChangeNet<sup>[24]</sup>及CSCDNet<sup>[25]</sup>作对比。表5为不同语义分割模型的实验结果,从表5可以看出,相较于其他网络,所提模型在精确率、召回率、F1分数方面均有提高,检测效果更好。本实验所使用的GPU设备为NVIDIA GeForce RTX 2080 Ti,发现在同其他语义分割网络的比较中,所提网络在训练速度上略有减慢。ChangeNet网络使用ResNet50作为特征提取模块,采用孪生网络和全卷积网络,相较于UNet网络,训练时间有所增加;CSCDNet采用孪生神经

表5 不同方法变化检测结果评价

Table 5 Evaluation of change detection results of different methods

Method	Precision / %	Recall / %	F1 / %	Time / h
UNet	72.507	69.421	70.864	8.7
ChangeNet	74.659	70.215	72.337	9.4
CSCDNet	80.295	82.347	81.362	11.3
Proposed method	82.508	85.232	83.324	10.1

网络ResNet18作为网络的编码器,相较于ChangeNet,训练性能有所提高;所提网络由于编码阶段使用残差网络ResNet50提取图像特征,在编码器的最深特征层引入空洞卷积和金字塔池化模块,解码阶段逐级引用注意力模块以关注重要特征,因此在训练时间上有所增加。

为了检测不同网络对不同尺度建筑物变化检测结果的影响,选择了多处地区来检测网络的性能,如图5所示,白色表示产生变化的区域。通过与地面真实标签对比发现,各个网络基本均能检测出来建筑物的变化范围。UNet网络在变化检测中,小尺度目标误检漏检现象严重,检测变化面积明显不足,且建筑物边界检测结果粗糙;ChangeNet由于使用残差网络提取特征,并结合卷积输出不同层的变化定位信息,使用了孪生神经网络结构,相较于UNet网络,小尺度目标误检漏检现象有所缓解,建筑物边界基本可以分辨;CSCDNet应用ResNet18作为网络的编码器,采用相关层的孪生神经网络结构来克服相机视角的影响,因此在变化检测结果中,对小目标建筑物检测效果有所改善,建筑物边界提取效果明显,但仍存在误检漏检现象;所提网络同时引入CBAM和PPM,采用逐级聚合的方式计算特征金字塔,融合多尺度特征,检测效果明显提升。结果表明,所提网络可以有效检测出中、小尺度建筑物并且能够有效地获取建筑物的边界信息,在建筑物边界的提取上效果最佳。

## 5 结 论

提出了一种基于深度学习的高分辨率遥感图像变化检测方法。在编码阶段,采用ResNet50网络逐级提取图像特征,在编码器最深特征层中通过引入空洞卷积和金字塔池化模块代替原来的卷积层,多尺度提取图像特征,解码阶段引入注意力模块突出有用特征,以恢复中、小尺度建筑物特征。在武汉大学大型变化检测数据集上进行测试,将所




图5 不同尺度建筑物变化检测结果对比。(a)时相遥感影像1;(b)时相遥感影像2;(c)地面真值;(d) UNet;(e) ChangeNet;(f) CSCDNet;(g)所提方法

Fig. 5 Comparison of detection results of building changes with different scales. (a) First-phase remote sensing image; (b) second-phase remote sensing image; (c) ground truth; (d) UNet; (e) ChangeNet; (f) CSCDNet; (g) proposed method

提方法的变化检测结果同 UNet、ChangeNet、CSCDNet 网络作对比。实验结果表明:所提改进后的网络可以准确地检测出遥感图像中建筑物的变化像素,相较于传统的语义分割模型,在精确率、召回率以及 F1 分数上均有提升,有效解决了不同尺度建筑物漏检误检以及分割边界不明显的问题,为变化检测研究提供了理论参考,对现实中街道违

建排查、土地利用情况、城市规划等方面有重大意义。

### 参考文献

[1] Hussain M, Chen D M, Cheng A, et al. Change detection from remotely sensed images: from pixel-based to object-based approaches[J]. ISPRS Journal

- of Photogrammetry and Remote Sensing, 2013, 80: 91-106.
- [2] Guimarães N, Pádua L, Marques P, et al. Forestry remote sensing from unmanned aerial vehicles: a review focusing on the data, processing and potentialities[J]. Remote Sensing, 2020, 12(6): 1046.
- [3] Jiang K, Wang Z Y, Yi P, et al. Edge-enhanced GAN for remote sensing image superresolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8): 5799-5812.
- [4] 付青, 郭晨, 罗文浪. 基于高分一号卫星遥感影像的土地利用变化检测[J]. 激光与光电子学进展, 2020, 57(16): 162802.  
Fu Q, Guo C, Luo W L. Land use change detection based on GF-1 satellite remote sensing images[J]. Laser & Optoelectronics Progress, 2020, 57(16): 162802.
- [5] Lyu H B, Lu H, Mou L C. Learning a transferable change rule from a recurrent neural network for land cover change detection[J]. Remote Sensing, 2016, 8(6): 506.
- [6] Rokni K, Ahmad A, Selamat A, et al. Water feature extraction and change detection using multitemporal Landsat imagery[J]. Remote Sensing, 2014, 6(5): 4173-4189.
- [7] Huang X, Zhu T T, Zhang L P, et al. A novel building change index for automatic building change detection from high-resolution remote sensing imagery [J]. Remote Sensing Letters, 2014, 5(8): 713-722.
- [8] 王丽涛, 王世新, 周艺, 等. 基于纹理特征的高分辨率遥感影像灾害监测应用[J]. 灾害学, 2014, 29(3): 97-101.  
Wang L T, Wang S X, Zhou Y, et al. Remote sensing change detection method based on texture characteristic in natural disaster monitoring[J]. Journal of Catastrophology, 2014, 29(3): 97-101.
- [9] 辛芳芳, 焦李成, 王桂婷, 等. 利用小波域 HMC 模型进行遥感图像变化检测[J]. 西安电子科技大学学报, 2012, 39(3): 43-49.  
Xin F F, Jiao L C, Wang G T, et al. Change detection in multi-temporal remote sensing images based on the wavelet-domain hidden Markov chain model[J]. Journal of Xidian University, 2012, 39(3): 43-49.
- [10] 施向丰, 帅梅琴, 申劲松. 基于多时相遥感图像智能变化检测方法的研究[J]. 测绘通报, 2012(9): 23-25.  
Shi X F, Shuai M Q, Shen J S. Study on the intelligent change detection methods on the basis of multi-temporal remotely sensed images[J]. Bulletin of Surveying and Mapping, 2012(9): 23-25.
- [11] Peng D F, Zhang Y J, Guan H Y. End-to-end change detection for high resolution satellite images using improved UNet++ [J]. Remote Sensing, 2019, 11(11): 1382.
- [12] 付青, 罗文浪, 吕敬祥. 基于 AlexNet 和支持向量机相结合的卫星遥感影像土地利用变化检测[J]. 激光与光电子学进展, 2020, 57(17): 172802.  
Fu Q, Luo W L, Lü J X. Land utilization change detection of satellite remote sensing image based on AlexNet and support vector machine[J]. Laser & Optoelectronics Progress, 2020, 57(17): 172802.
- [13] Zhang P Z, Gong M G, Su L Z, et al. Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 116: 24-41.
- [14] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [15] 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.  
Zhang C J, An R, Ma L. Building change detection in remote sensing image based on improved U-Net [J]. Computer Engineering and Applications, 2021, 57(3): 239-246.
- [16] 胡蕾, 江宇, 李进, 等. 一种多尺度稀疏卷积的高分辨率遥感图像变化检测方法[J]. 小型微型计算机系统, 2020, 41(11): 2365-2370.  
Hu L, Jiang Y, Li J, et al. Change detection method for high-resolution remote sensing image based on multi-scale and sparse convolution[J]. Journal of Chinese Computer Systems, 2020, 41(11): 2365-2370.
- [17] 陈璐, 管霜霜. 基于深度学习的城市高分遥感图像变化检测方法的研究[J]. 计算机应用研究, 2020, 37(S1): 320-323.  
Chen L, Guan S S. Research on urban high-resolution remote sensing image changing detection method based on deep learning[J]. Application Research of Computers, 2020, 37(S1): 320-323.
- [18] 向阳, 赵银娣, 董霁红. 基于改进 UNet 孪生网络的遥感影像矿区变化检测[J]. 煤炭学报, 2019, 44(12): 3773-3780.  
Xiang Y, Zhao Y D, Dong J H. Remote sensing



- image mining area change detection based on improved UNet siamese network[J]. *Journal of China Coal Society*, 2019, 44(12): 3773-3780.
- [19] 张哲晗, 方薇, 杜丽丽, 等. 基于编码-解码卷积神经网络的遥感图像语义分割[J]. *光学学报*, 2020, 40(3): 0310001.  
Zhang Z H, Fang W, Du L L, et al. Semantic segmentation of remote sensing image based on encoder-decoder convolutional neural network[J]. *Acta Optica Sinica*, 2020, 40(3): 0310001.
- [20] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6230-6239.
- [21] Xu B B, Yang F, Yang J F, et al. SPNet: superpixel pyramid network for scene parsing[C]//2018 Chinese Automation Congress (CAC), November 30-December 2, 2018, Xi'an, China. New York: IEEE Press, 2018: 3690-3695.
- [22] Ji S P, Wei S Q, Lu M. Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(1): 574-586.
- [23] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 11211: 234-241.
- [24] Varghese A, Gubbi J, Ramaswamy A, et al. ChangeNet: a deep learning architecture for visual change detection[M]//Leal-Taixé L, Roth S. *Computer vision-ECCV 2018 workshops. Lecture notes in computer science*. Cham: Springer, 2019, 11130: 129-145.
- [25] Sakurada K, Shibuya M, Wang W M. Weakly supervised silhouette-based semantic scene change detection[C]//2020 IEEE International Conference on Robotics and Automation, May 31-August 31, 2020, Paris, France. New York: IEEE Press, 2020: 6861-6867.