

城市区域建筑物变化检测算法研究与应用

李岩

长春市规划编制研究中心（长春市城乡规划设计研究院）

DOI: 10.12238/jpm.v5i12.7475

[摘要] 随着遥感技术的发展与遥感影像更新频率的提升，自动化建筑物识别与变化检测在市域规划与管理、城市数据更新等领域都起着极为重要的作用。本文针对建筑物变化特征复杂的特性，提出了一种基于深度学习的建筑物变化检测方法。首先，针对卫星影像特征建立建筑物变化样本数据库，并利用翻转、改变亮度等多种方式进行样本的扩充；然后，结合深度学习 ResNet、Unet 等网络结构进行算法的优化与改善，得到优化后的变化检测网络结构；接着，用样本库进行网络参数的训练；最终得到适合区域的变化检测网络模型。通过在某市 0.5m 高分辨率卫星数据上进行多种算法的对比实验，表明本文方法能够有效进行城市建筑物变化检测，并能得到较优的效果。

[关键词] 遥感影像；建筑物变化；深度学习；卷积神经网络

Research and application of building change detection algorithm in urban areas

Li Yan

Changchun Planning Research Center (Changchun Urban and Rural Planning and Design Institute)

[Abstract] With the development of remote sensing technology and the improvement of the frequency of remote sensing image update, automated building identification and change detection play a very important role in the urban planning and management, urban data update and other fields. Based on the complex characteristics of building change, this paper proposes a building change detection method based on deep learning. Firstly, establish the building change sample database for the satellite image features, and expand the sample by flipping and changing the brightness; then, optimize the algorithm and improve the network structure such as deep learning ResNet and Unet, and get the optimized change detection network structure; then, train the network parameters with the sample database; and finally get the change detection network model suitable for regions. By comparing the experiment of various algorithms on the 0.5m high resolution satellite data in a city, we show that the method can effectively detect the changes of urban buildings and get better results.

[Key words] remote sensing image; building change; deep learning; convolutional neural network

引言

建筑物作为城市最主要的构成部分之一，一直是遥感影像解译的重点研究对象。建筑物的空间分布在城市规划与管理领域有着重要意义，其专题识别与变化检测结果在城市数据更新、违法建筑监测等方面都至关重要。但是，由于其光谱、纹理、几何形状等特征的复杂性，以及高分辨率遥感影像中城市背景的多样性，城市建筑物变化检测技术发展仍不完善，在生产中仍以人工目视判读为主，随着遥感影像更新频率的提升，普适性和实用性的建筑物变化检测方法亟待发展。针对上述深度学习在建筑物变化检测中的问题，本文提出了一种基于残差网络与 U 型网络相结合的网络结构，将建筑物分类网络与变化检测网络深度融合，得到一种相对高效、准确的检测模式，实现了大场景下的建筑物识别与变化检测，并能得到较为理想的结果。

1 方法

1.1 深度学习影像特征提取与分类网络

由于城市建筑物尺寸差异大，形状、纹理与色彩等方面都

较为复杂，需要对不同尺度的特征均进行提取分析，因此本文采用以 ResNet 为核心，以 Unet 为整体架构的方式，构建与优化深度学习网络。同时，为了兼顾不同尺度与比例的建筑物，本文采用特征金字塔网络 (Feature Pyramid Network, FPN) 对 Unet 的结构进行优化，得到如图 1 的建筑物检测网络：



图 1 建筑物检测网络

由图 1 可以看出输入影像为 400x400x3 (长 x 宽 x 波段) 的矩阵格式，经过卷积与反卷积的深度学习网络计算，得到 400x400x1 的格式，即对每个像素都得到一个分类的标记。

1.2 深度学习变化检测网络

为了在变化检测中引入建筑物的特征，从而改善建筑物变化检测结果的精度，本文设计了一种变化检测网络结构，既可

以有效利用建筑物分类网络的训练结果，直接将建筑物分类过程中提取的多层特征信息用于变化检测网络中，又可以有效地将分类与变化检测两个网络分开，允许通过分别优化两种样本

来优化两部分网络，最终，同时得到更好的建筑物分类和变化检测结果。

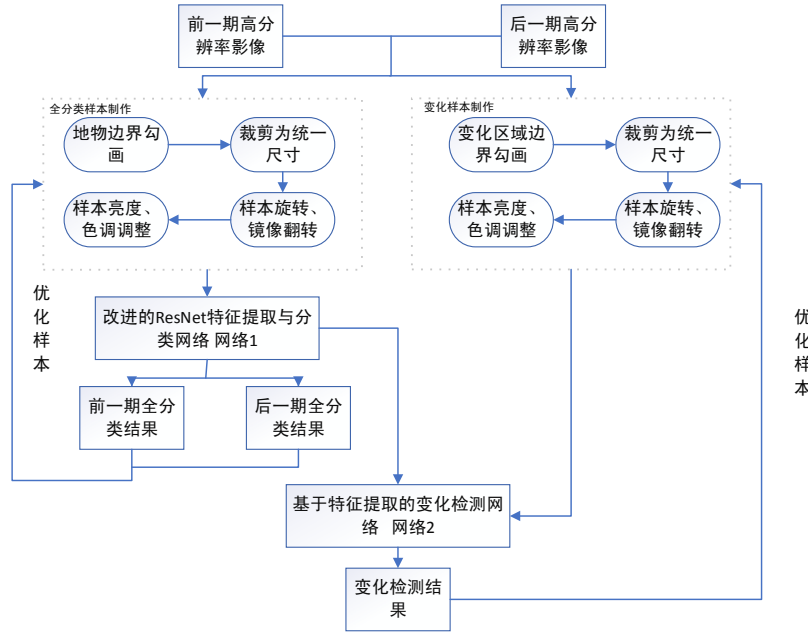


图 2 变化检测流程图

图 2 是变化检测的整体流程，输入是前后两期影像，输出是变化检测结果从图中可以看出，建筑物分类样本与变化样本是分别制作与优化的。通过特征分类与变化检测两个网

络分别训练，得到最终结果，该流程可以很好地分割各个任务模块，提升网络优化效率。本文变化检测网络的结构如图 3 所示。

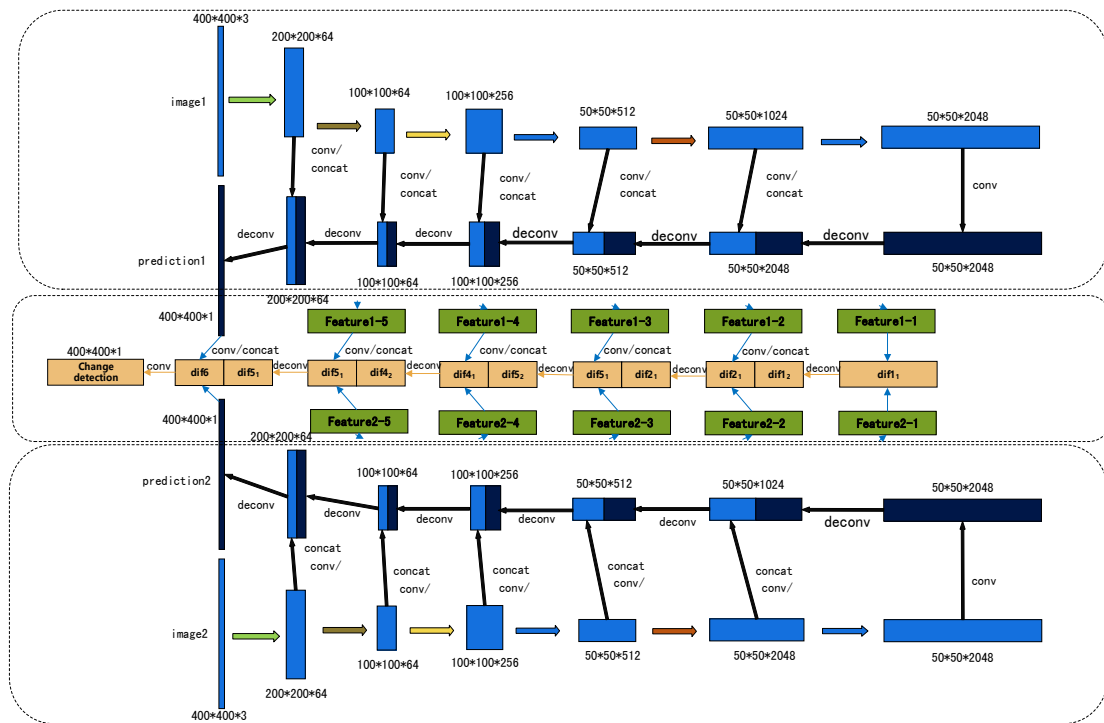


图 3 变化检测网络结构图

图 3 中两个外边虚线框，是分别对两期影像进行了建筑物分类网络的运算。其与图 1 的结构相同；中间虚线框是变化检测网络，是在分类网络的基础上，进行了部分网络参数的提取，最终实现了建筑物变化检测的计算。

从图 3 中可以看出，首先对前后两期影像 image1 与 image2

用已经训练好的建筑物分类网络的参数，分别进行特征提取与反卷积升采样。由于在反卷积的过程中，各层都有效包含了不同尺度下影像的特征，所以将五个隐藏层与 prediction 层都作为变化检测网络的输入（绿色矩形 Feature），图中 dif1₁ 为 Feature1-1 与 Feature2-1 差值的绝对值（矩阵为

50x50x2048), 经归一化后反卷积得到 $dif1_2$ (矩阵为 50x50x256), 然后 Feature1-2 与 Feature2-2 也取差值与绝对值, 经过 3x3 卷积处理, 得至 50x50x256 的矩阵 $dif2_1$, 并与 $dif1_2$ 通过 concat 得到 50x50x512 的矩阵, 依此类推得到最终的 400x400x1 的 Changedetection 预测结果, 将此结果与变化标定样本计算 softmaxcrossentropy 值。其中 softmax 计算过程如下:

$$S_j = \frac{e^{a_j}}{\sum_k^n e^{a_k}} \quad (1)$$

式中: S_j 为 softmax 每个分类的输出结果, k 表示当前类别, n 表示总类别数 ($0 < k \leq n$), a_j 表示该分类的值, 式中分母表示 k 取值从 0 到 n 的 e^{a_k} 的综合, 表现分类结果的一种整体情况, 分子 e^{a_j} 表示在第 i 个类别时的计算数值, 然后将计



图4 分类样本勾画示意图

变化检测样本数据集同样使用该市高分辨率光学卫星影像, 空间分辨率也是 0.5m, 红、绿、蓝三个波段参与计算。为了降低单期影像色彩与光照的影响, 制作了多个时间段的变化样本, 分别对 2018 年该市 4 个季度以及 2018 年第 4 季度与 2019 年第 I 季度的建筑物变化区域制作了变化样本, 构建了建筑物



图5 变化检测样本勾画示意图

由于样本只制作了建筑物拆除的类型, 对于建筑物新增的部分, 则将前后两期影像调换顺序后进行检测。

3 结果分析

本实验在单机双 GPU 的测试计算机上进行运算, GPU 型号为 NVIDIA RTX2080Ti, python 版本为 3.7, 训练平台为 tensorflow1.13.1, batchsize 为 4, 测试影像大小为 400x400 像素, 建筑物提取的影像波段数为 3 波段 (红、绿、蓝 3 波段), 变化检测影像波段数为 6 波段 (前后影像的红、绿、蓝波段), 建筑物分类的训练时长约为 40 小时, 变化检测训练时长约为



图6 建筑物检测结果对比图

算得到 S_j 作为输入, 进行交叉熵的计算:

$$H_{(y, y')} = \sum_i^n y_i \log y_i' \quad (2)$$

式中: i 表示当前类别, n 表示所有类别 ($0 < i \leq n$), y_i 为第 i 类的真实值 (期望输出), y_i' 为 softmax 的输出结果 S_j 向量中的对应的分量, 用此公式可以对分类结果进行评估。

2 数据集

分类样本数据集采用该市 2018 年第 2、3 季度的高景一号光学卫星影像, 空间分辨率为 0.5m, 红、绿、蓝三个波段参与计算, 在该市均匀选取 46763 个建筑物样本的图斑, 共计 70.4196km²。考虑季节与光照条件对遥感影像质量的影响, 对制作好的样本进行旋转、翻转、镜像等处理, 色彩方面也在 HSV 空间进行了亮度、饱和度与色调的调整, 有效扩充了样本量, 提升了模型的准确率。

变化的样本数据集, 形成了 309km² 区域的样本数据, 实际勾绘出的建筑物变化区域约 8.1km², 为了进一步扩充样本, 和分类样本制作一样, 也进行了旋转、翻转、镜像等几何处理与亮度、饱和度与色调调整等色彩处理, 最终形成了变化检测样本数据集, 用于该市的变化检测。

72 小时。

3.1 建筑物提取的对比

实验结果提取了该市约 130 余万栋建筑, 面积约为 640km², 实现了大面积大数据量下的高分辨率遥感影像自动分类。本文对两块实验区 (各 10km²) 进行了三种结果的对比, 即原始的 ResNet50、本文方法改进后的 ResNet 与 VGG19 网络。三种网络结构都用相同的某建筑物数据集进行实验对比, 其局部图如图 6 所示。

图6两个实验区存在低矮规则的区域与高楼部分。可以看出,在建筑物较为简单、均一、低矮的情况下,三种网络都可以达到一个较好的效果,可以满足建筑物提取的要求,改进的ResNet50网络在形状完整性上略有改善,但是在形状复杂且高楼较多的情况下,ResNet50在改进后的效果要优于原始的效果,在漏检与误检方面都有所提升,而用本文方法同样对ResNet50与VGG19进行改进,从结果可以看出,ResNet50的边界会优于VGG19。

对两块实验区的结果进行定量的精度评价,得到下表中结果。其中,表1为复杂高大建筑物的检测结果,表2为简单低矮建筑物的检测结果。

表中“改进ResNet50”与“改进VGG19”都是经过本文方法优化后的网络,ResNet50则是未经优化的网络。可以看出,在精度、召回率和交并比三个方面,本文的改进方法都有较明显的优势,但由于精度评价的对象包括乡村和城市的大范围建筑物检测结果,而目前样本量虽有一定积累,针对全市的建筑物还稍显不足,所以检测的精度还有待进一步提升。



图7变化检测结果对比图

从图7的几组实验可以看出,本文改进后的有提升,未改进的网络有较多的小面积误检,漏检结果优于未改进的网络,在漏检率和误检率上提升也较为明显,尤其当范围从实验区扩大到整个市域以后,小面积变化图斑的误检会带来巨大的额外

	Precision	Recall	IoU
改进 ResNet50	0.8926	0.8454	0.8233
ResNet50	0.7932	0.7567	0.6421
改进 VGG19	0.8793	0.7397	0.7102

	Precision	Recall	IoU
改进 ResNet50	0.9092	0.8532	0.8135
ResNet50	0.8409	0.7452	0.6421
改进 VGG19	0.8793	0.7397	0.7102

3.2 变化检测结果对比

本文将未改进的ResNet50、改进的VGG19与改进的ResNet50作为不同的基础网络,都投入到本文的改进变化检测方法中进行实验,并将变化检测结果进行边缘优化以及矢量化,从而减小数据量,也便于后续面积与块数的统计;对全市范围进行建筑物变化检测,最终得到图7的局部变化区域检测结果。可以看出,三种方法都可以有效地检测出大块的变化区域,而从漏检率、错检率以及边缘的吻合程度方面看,本文的变化检测方法结合改进的ResNet50网络的效果最好。

工作量,而漏检的排查工作也会非常大,无法体现深度学习自动识别的优势。因此,本文的改进方法可以有效地改善分类与变化检测效果,辅助实际工作应用。

表格3 变化检测出率评价结果

	块数(块)	块数检出率	面积(km ²)	面积检出率
人工标绘图斑总计	7817		8.1131	
改进 ResNet50	5397	69.0418%	5.2643	64.8864%
ResNet50	4972	63.6050%	4.9614	61.1530%
改进 VGG19	5011	64.1039%	5.0726	62.5236%
	总计	6674	8.0374	
100m ² 以上	本文检出	4924	73.7788%	65.4329%
	ResNet50	4635	69.4486%	62.0101%
	改进 VGG19	4716	70.6623%	62.8114%
	总计	4988	7.7875	
200m ² 以上	本文检出	3752	75.2205%	67.0844%
	ResNet50	3491	69.9880%	62.4295%
	改进 VGG19	3561	71.3913%	63.5030%

由于在生产中变化检测更注重目标的检出率,希望有变化的部分都能以图斑的形式检测出来,所以在本文的结果评价中,以全市人工手绘变化区域(总计7817块图斑,约8.1km²)为标准,对2018年第2、3季度两期影像变化检测进行结果评估,统计了自动检测的变化区域检出人工手绘图斑的块数和检出面积,结果见表3。

从表3可以看出,改进后的ResNet50效果有了很好的提升,总体的块数检出率从63.61%提升至69.04%,面积检出率从61.15%提升至64.89%,并且随着图斑面积的增长,面积检出率和块数检出率都有所提升,对200m²以上的检出率达到75%,这说明,算法对于大面积的变化检测有很好的检测效果,但是对于小面积的变化区域,还存在一定的漏检情况。这种漏检情况有望通过加强小面积样本、改进特征提取方式等方法进行改善。在遥感影像建筑物提取的结果评估方面,常用的精度评价标准有Precision(精度)、Recall(召回率)与IoU(交

并比)3个指标,表4和表5是两块实验区三种算法精度评价对比的结果。

4 结语

本文提出了利用深度学习进行光学卫星遥感影像变化检测的方法,将建筑物的特征学习结果直接应用到变化检测的网络训练中,通过实验对比分析发现,本文方法能够有效提高建筑物检测与变化检测的正确率。深度学习作为变化检测的有效手段之一,可以大幅减少人工检测的工作量,但由于本文设计的变化检测网络调用了建筑物分类的网络参数,因此,分类网络的精度会影响变化检测的结果。后续将在样本数据集扩充和模型优化方面做进一步研究。

[参考文献]

[1]臧珂.结合非对称卷积组与通道注意力的遥感影像建筑检测方法[J].测绘与空间地理信息,2024,47(10):87-90.