

doi: 10.6046/gtzyyg.2019.04.21

引用格式: 吴海平, 黄世存. 基于深度学习的新增建设用地信息提取试验研究——全国土地利用遥感监测工程创新探索[J]. 国土资源遥感, 2019, 31(4): 159–166. (Wu H P, Huang S C. Research on new construction land information extraction based on deep learning: Innovation exploration of the national project of land use monitoring via remote sensing[J]. Remote Sensing for Land and Resources, 2019, 31(4): 159–166.)

# 基于深度学习的新增建设用地信息提取试验研究 ——全国土地利用遥感监测工程创新探索

吴海平<sup>1</sup>, 黄世存<sup>2</sup>

(1. 中国国土勘测规划院, 北京 100035; 2. 中国资源卫星应用中心, 北京 100094)

**摘要:** 以全国土地利用遥感监测工程积累的几百万个新增建设地图斑为训练样本, 利用卷积神经网络完成深度学习变化检测模型的训练, 实现重大工程中新增建设用地信息的自动提取。与人工提取结果进行的对比分析表明, 基于深度学习的新增建设用地自动检测技术在全国土地利用遥感监测工程中有很好的适用性, 当新增建设用地信息提取查全率达80%左右时, 辅以少量的人工干预可大大提高工程实施效率。

**关键词:** 深度学习; 土地利用; 遥感监测; 新增建设用地

**中图分类号:** TP 79 **文献标志码:** A **文章编号:** 1001-070X(2019)04-0159-08

## 0 引言

随着遥感技术和卫星发射技术的快速发展, 2010年第二次全国土地调查结束以后, 国土资源管理领域从国家层面上逐渐建立了年度土地利用遥感监测新机制, 每年采用9—12月份的高分辨率卫星遥感影像, 对全国范围进行一次年度土地利用动态遥感监测, 重点提取以新增建设用地为主的土地利用变化信息, 监测结果用于年度土地利用变更调查、土地卫片执法检查 and 土地督察等业务。因为监测结果直接服务于国土资源管理工作, 所以对新增建设用地提取的准确性和按时完成的时效性要求非常高。该工程已实施多年, 曾多次尝试利用传统的分类方法、面向对象的分割方法等自动检测技术进行探索试验, 但受制于自动检测技术不够完善或对操作员的专业知识水平要求太高, 以及工程本身具有多源、多尺度卫星数据源, 数据质量参差不齐, 信息类别复杂繁多等特点, 自动检测方法仍然只是辅助手段, 更主要的是依赖大量人力目视判读。

近几年来, 作为人工智能的核心技术, 深度学习在图像识别、安防监控、智能驾驶、无人机、语音识别

及自然语言处理等领域取得了大量关键性突破和实际应用, 同时也被逐渐引入遥感图像分类、识别及目标检测等任务中。但卫星遥感影像更为复杂, 要全面达到理想状态很难, 如果只是针对特定单一目标进行检测则相对容易。在全国土地利用遥感监测工程中, 主要是提取新增建设用地, 目标单一, 因此, 为能提高工程实施效率, 本文尝试利用深度学习技术进行新增建设用地信息提取的应用探索。

## 1 深度学习技术简介

在深度学习技术方面, Hinton等<sup>[1]</sup>提出利用深度信念网络(deep belief network, DBN)进行数据分类并取得突破性进展, 此后各研究及工程领域纷纷采用深度学习方法进行应用试验。Minh等<sup>[2]</sup>于2010年首次将深度学习应用于遥感领域, 利用深度信念网络模型对机载影像进行道路的目标识别。自此, 深度学习技术逐渐被应用于高分辨率影像分类、信息提取及变化检测中。国内刘大伟等<sup>[3]</sup>基于深度学习技术实现了高空间分辨率影像的分类任务, 并与传统方法进行对比, 结果表明, 深度学习技术能够更加准确地挖掘高分影像的空间分布规律; 高常鑫等<sup>[4]</sup>通过分层方法建立深度学习模型, 完成了对

收稿日期: 2018-11-30; 修订日期: 2019-02-22

基金项目: 自然资源部专项项目“全国土地利用变更调查监测与核查”(编号: ZX180901)资助。

第一作者: 吴海平(1978-), 女, 硕士, 高级工程师, 主要从事土地资源调查、土地利用遥感监测等方面的研究。Email: wuhaiping@

万方数据 lspi.org.cn.

高分影像的高精度分类;韩洁等<sup>[5]</sup>基于深度学习技术开展了遥感影像城市扩展方法研究,研究表明深度学习的生产者精度和 Kappa 系数都比传统方法要高,适用于城市建成区变化趋势研究;张鑫龙等<sup>[6]</sup>提出通过构建并训练包含标签层的高斯伯努利深度限制玻尔兹曼机模型,可以提取变化和未变化区域深层特征,有效辨别变化区域;阚希等<sup>[7]</sup>利用多光谱卫星遥感和深度学习方法进行了青藏高原积雪判别;陈洋等<sup>[8]</sup>提出了基于深度学习的资源三号卫星遥感影像云检测方法;朱祺夫等<sup>[9]</sup>提出了基于深度学习的遥感影像城市建筑用地提取方法。

深度学习技术的主要思想是基于神经网络进行信息识别,通过大量样例的训练(学习),得到网络最优参数(函数),再应用该网络从输入数据得到最优类别判断的过程。在影像识别和变化检测领域,卷积神经网络是最常用的深度学习方法。卷积神经网络(convolutional neural network, CNN)是一种带有卷积结构的深度神经网络,它的权值共享网络结构使之更类似于生物神经网络,降低了网络模型的复杂度,减少了权值的数量。这个优点在网络的输入是多维图像时表现得更为明显,图像可以直接作为网络的输入,避免了传统识别算法中复杂的特征提取和数据重建过程。卷积结构可以减少深层网络占

用的内存量,也可以减少网络的参数个数,缓解模型的过拟合问题<sup>[10]</sup>。深度学习模型层数多,常常十几层甚至几十层,多则几百层到上千层。通过逐层的特征提取,逐渐使分类和检测结果更加精准。开始几层通常是卷积层和下采样层的交替,在靠近输出层的最后几层网络通常是全连接网络。卷积神经网络的训练过程主要是学习卷积层的卷积核参数和层间连接权重等网络参数,预测过程主要是基于输入图像和网络参数计算类别标签。

## 2 全国土地利用遥感监测分类体系



基于卫星遥感数据的影像特征,从国土资源管理的实际需求出发,全国土地利用遥感监测工程经过逐年完善,建立了年度土地利用变更调查 12 个一级类、27 个二级类的遥感监测分类体系。本次试验在此分类体系基础上进行了适当删减。因该体系中部分类型非当年实际新增建设用地,或赋予过多的管理属性,或是某类的细化地类,或无法直接依据遥感影像进行判断。试验过程中为客观评价基于遥感数据的测试结果,仅针对其中主要的 4 个一级类、16 个二级类进行研究与评价。这 4 个类型也是新增建设用地类型中的主要地类(表 1)。

表 1 新增建设用地分类体系

Tab. 1 Classification system of new constructed land

一级分类代码	二级分类代码	分类含义	影像特征
1		前时相影像有植被覆盖或明显非建设痕迹,后时相影像有明显建设特征(如地基、建筑物、构筑物、广场、公园等)。根据影像特征再细分为 ABCDEF 共 6 个二级类	
	1A	可确定为住宅小区、工厂、高层建筑、集中建设的大规模农村居民点、学校、运动场、机场等大型建设项目及可确定为以上用地类型的建设地基	
	1B	不能明确归为 A 类的建筑或建设项目,具有或疑似彩钢特征的建设项目,零散分布的农村居民点,以及已建项目内部新建或扩建的附属绿地、广场、停车场	
	1C	内陆地区大型水工建筑、港口码头、水库水面等	
	1D	非建设用地附属的独立广场、停车场、露天货站等以地面硬化为主的用地	
	1E	公园、休憩及美化环境的绿化用地	

(续表)

一级分类代码	二级分类代码	分类含义	影像特征
	1F	简易的疑似设施农用地或简易临时建筑	
2		前时相影像有植被覆盖或明显非建设痕迹,后时相影像有明显建设推填土特征	
3		前时相影像有明显建设推填土特征,后时相影像有明显建设特征(如地基、建筑物、构筑物、广场、公园等);或前时相影像为低矮建筑,后时相影像翻建为较大规模建筑,如居住小区、高层建筑或规模化化工厂等,根据影像特征再细分为 ABCDEF 六个二级类,划分标准与“第一类”相同	
7		前时相影像有植被覆盖或没有明显建设,后时相影像有明显道路或大型沟渠特征(包括在建推土、搭建桥墩等);或前时相影像道路或大型沟渠在建,后时相影像明显建成特征(包括路面硬化、运行使用等),根据影像特征再细分为 ABCD 共 4 个二级类	
	7A	前时相未建或动土在建,后时相基本建成的道路。表现为路面已完成硬化、水泥浇筑或铺油等基本具备通车条件	
	7B	前时相未建,后时相动土在建道路。表现为路边有堆土、路面宽度不均匀、分段在建等主体施工阶段,以及虽然道路已连通,路形基本规则、宽度基本确定,但路面仍为未压实的土面、不平整、未硬化、铺油等后期路面处理阶段	
	7C	在建或建成的大型开发建设区域内部路网	
	7D	在建或建成的大型沟渠(如南水北调等)	

### 3 样本训练

#### 3.1 技术路线

根据遥感监测工程的数据特点和深度学习的关键步骤,样本训练过程中主要采用了以下技术路线。

1) 数据归一化处理。遥感监测工程所用数据来源多种多样,既有多波段多光谱数据也有单波段全色数据,数据空间分辨率从 0.5 m 到 5 m 不等。为满足样本训练需要,首先对试验数据进行归一化处理,通过减少或增加通道的方式将不同波段的影像处理成 3 个波段;然后根据训练样本影像实际空间分辨率,通过重采样的方式将不同分辨率的数据处理成相应的空间分辨率。

2) 训练模型。建立模型是深度学习技术的关键。近年来,深度模型不断改进,出现了很多有广泛用途的模型。本研究使用的模型是以 ResNet 为基

础模型,经过改造而适用于变化检测的应用。ResNet 模型利用残差模块,解决了深度模型的梯度消失问题,同时提高了模型的训练效率,把 ImageNet 的图像分类精度推高到超过专家的水平。

3) 训练样本。训练过程中,通过增强样本技术,进一步增加样本变化,提高模型适应性。为提高模型训练的收敛性和避免过度拟合,对模型的一些超参数进行动态调节,尤其是学习率参数,选取指数递减函数动态调节梯度下降幅度,初始时加快一点收敛速度,随后放慢改变幅度,减少错失最优结果的可能性。另外,利用屏蔽神经元技术减少过度拟合的可能性。

4) 变化监测。变化检测采用高斯混合模型(Gaussian mixture model, GMM)、马尔科夫随机场能量优化算法 GraphCut、基于分水岭的过分割算法等,根据变化检测结果逐步调整参数和阈值,并综合考虑定性、定量评价结果和计算耗时等因素,最终得出相对的优化模型。

### 3.2 训练样本选取

训练样本的数量和代表性是影像分类的关键,不同的选取方法也会影响分类的效果<sup>[1]</sup>。本文试验的目的是为全国土地利用遥感监测工程做技术创新探索,因此,结合实际应用需求,以监测工程实际提取的新增建设用地图斑作为试验的训练样本。训练样本选取过程是,首先考虑到地区差异,从北方平原地区、南方丘陵山区、东部沿海地区等地方选择实际提取的新增建设用地图斑,共选取 2 万个图斑;然后再根据本文的分类体系进行筛选,共筛选出 1.6 万个新增建设用地图斑,8 207 个作为训练样本,另外 7 793 个作为测试样本。

样本涉及到的卫星数据源包括高分一号、北京二号、资源一号 02C、Beimos - 2, KasEosat - 2, Planet labs 和 Repideye 等,分辨率有 1 m, 2 m, 5 m 等多个尺度,前后时相为 2016 年 9—12 月和 2017 年 9—12 月。

### 3.3 训练样本处理及训练

本文设计并使用了一种两路卷积神经网络,通过使用卷积核计算卷积,对图像进行特征提取,生成相应的特征图像。主要处理流程如图 1 所示。

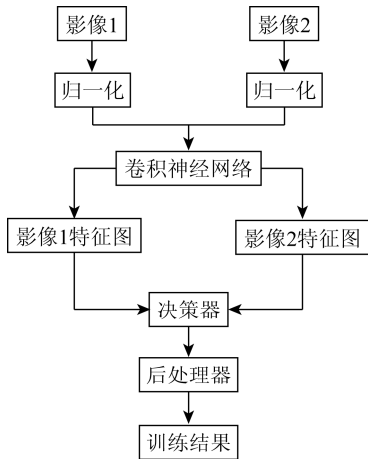


图 1 训练样本流程图

Fig. 1 Flowchart of deep learning method

### 3.4 训练样本精度评价

根据图斑的集中分布情况将其中的 7 793 个图斑作为测试样本,这些测试样本集中分布在 5 个样本测试区域,对比分析计算耗时、人工检测的图斑个数、机器检测出的图斑个数,并从数量和面积 2 方面计算图斑检测查全率、查准率、虚警率和漏检率。计算公式分别为

$$\text{查全率} = \frac{\text{检测出的样本图斑个数}}{\text{所有}}$$

$$\text{测试样本图斑个数} \times 100\% ; \quad (1)$$

$$\text{查准率} = \frac{\text{检测出的样本图斑面积}}{\text{所有}}$$

$$\text{测试样本图斑面积} \times 100\% ; \quad (2)$$

$$\text{虚警率} = \frac{\text{检测出的非样本图斑个数}}{\text{检测}}$$

$$\text{出的样本图斑个数} \times 100\% ; \quad (3)$$

$$\text{漏检率} = \frac{\text{未检测出的图斑个数}}{\text{测试}}$$

$$\text{样本中图斑个数} \times 100\% 。 \quad (4)$$

虚警率和漏检率是一对矛盾体,结合实际工程需要,主要目的是提高检测精度和工作效率,尽可能减少人工干预,需要平衡虚警率和漏警率的接受程度。虚警率低,漏检率则高,影响监测成果质量,不符合成果精度要求;如果接受较高的虚警率,则会给后期处理带来较多的工作量,不符合提高工程效率的需求。因此,综合各种因素后,经过多次调整与测试,找到平衡点,得出本文最为适合的相对优化模型。

经多次调试,本文最终使用的深度差异模型约 150 层,训练后模型大小约 40 MB,采用最终模型得出的检测结果见表 2。

表 2 深度学习检测精度评价表

Tab. 2 Evaluation of accuracy by deep learning

测试区域	1 号区域	2 号区域	3 号区域	4 号区域	5 号区域
程序检测图斑/个	721	2 734	5 231	1 643	1 756
人工提取图斑/个	441	1 827	3 436	1 193	896
计算耗时/h	0.5	1	1.5	1.2	1
人工提取耗时/h	8	32	62	22	16
数量查全率/%	81.9	78.0	83.0	85.0	74.0
数量虚警率/%	99.7	91.9	83.5	62.0	164.9
数量漏检率/%	18.1	22.0	17.0	15.0	26.0
面积查准率/%	21.1	18.3	17.9	25.5	20.4

通过试验可以看出,从效率方面,自动检测效率比人工工作效率高十几倍,甚至几十倍;从精度方面,自动检测可检测出 70% ~ 80% 的图斑数量;不足 30% 的小面积图斑虚警率非常高。尽管测试结果难以达到理想状态,但这对于工程来讲已是很大的进步,如果辅以一定的人机交互,在不损失检测精度的条件下能大大提高工作效率。

局部检测结果如图 2 (红色框线中为工程实际提取结果)。

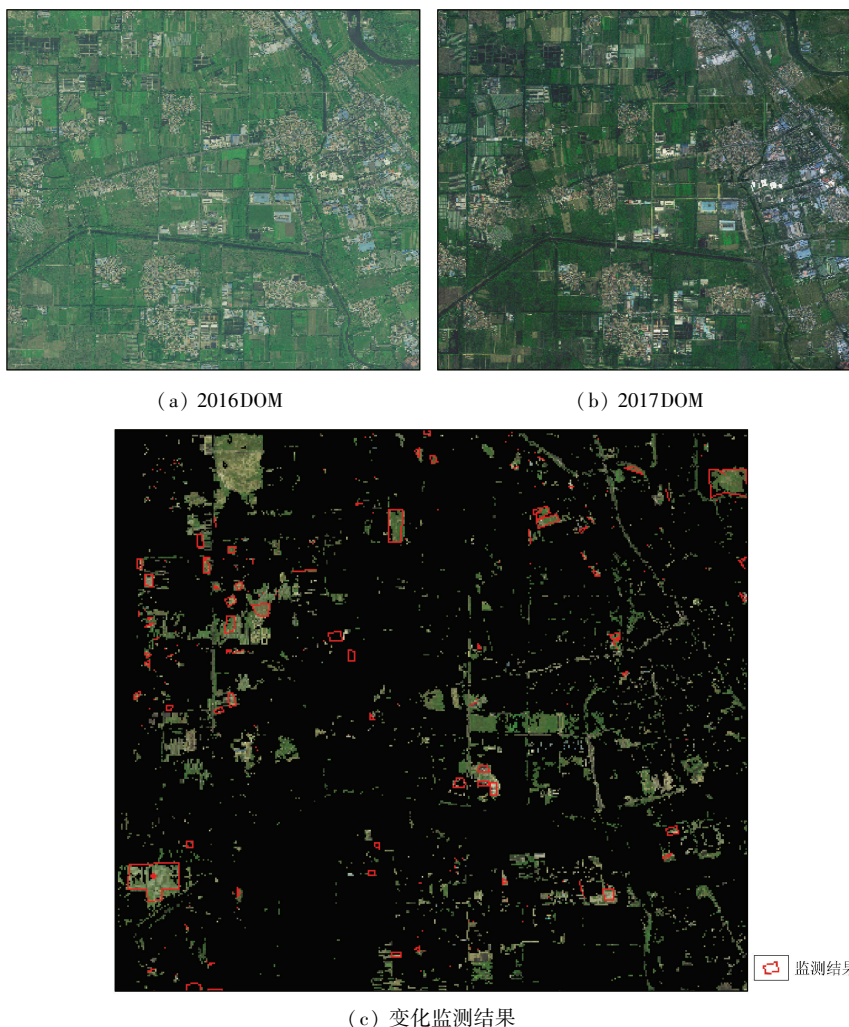


图2 基于深度学习的变化监测结果

Fig.2 Result of land use changes detecting based on deep learning

1.9 万亩<sup>①</sup>。各类型详见表3。

## 4 试验与分析

### 4.1 试验区与数据源

本文试验区有2个,一是北京市通州区,作为平原地区土地利用状况的代表;二是四川省资阳市雁江区,作为丘陵山区土地利用状况的代表。

#### 4.1.1 北京市通州区

通州区2016年和2017年度遥感数据源均为北京2号数据,前时相为2016年10—11月,涉及6景,侧视角低于10°,后时相为2017年9—10月,涉及8景,侧视角低于15°。

通州区经济发展迅速,尤其成为北京市副中心之后,市政府迁移通州,近几年土地利用变化频繁,新增建设用地量较大,2017年度遥感监测信息提取实际作业过程中,基于人工目视判读,并经过多级质量检查后确定提取的新增建设用地图斑有786个,

表3 通州区新增建设用地统计表

Tab.3 Statistics of new constructed land of Tongzhou District

图斑类型	图斑个数	图斑面积/亩
1A	11	148.9
1B	249	1 395.2
1C	2	15.3
1D	9	91.0
1E	42	6 485.3
1F	7	29.3
2	197	4 747.8
3A	7	125.5
3B	100	581.4
3D	6	41.1
3E	12	1 536.1
3F	3	15.3
7A	32	146.2
7B	108	3 712.5
7D	1	5.4

① 1亩=666.7m<sup>2</sup>

### 4.1.2 四川省资阳市雁江区

雁江区 2016 年度遥感数据源为 SPOT6 数据, 时相为 2016 年 11 月, 涉及 2 景, 侧视角低于 15°。2017 年度遥感数据源为高分二号、资源三号和 SPOT6, 时相为 2017 年 9—11 月, 涉及 5 景, 侧视角低于 12°。

雁江区属典型的四川盆地红岩丘陵区。2017 年度遥感监测信息提取实际作业过程中, 基于人工目视判读, 并经过多级质量检查后确定提取的新增建设用地图斑有 248 个, 1 901 亩。各类型详见表 4。

**表 4 雁江区新增建设用地统计表**  
**Tab. 4 Statistics of new constructed land of Yanjiang District**

图斑类型	图斑个数	图斑面积/亩
1A	5	45.9
1B	135	312.5
1D	2	21.5
1E	1	15.4
2	43	1 000.6
3A	3	59.1
3B	30	245.0
3D	2	3.6
7A	24	121.1
7B	3	76.8

### 4.2 新增建设用地实际检测结果与分析

测试样本评价结束后, 把 7 793 个图斑作为新的训练样本继续训练, 然后以完整区县为单位, 对北京市通州区和四川省雁江区 2 区进行实际新增建设用地变化检测, 并与人工目视判读结果进行对比分析。

检测过程中根据检测结果的关注重点不同进行参数设置与调试, 如果追求较高的查全率则必须牺牲准确率, 并且会导致非常高的虚警率; 如果虚警率太高, 要达到工程标准需要大量人工后处理, 与提高工程效率的初衷相违背, 失去试验的意义; 如果适当降低对查全率的要求, 能够提高准确率降低虚警率, 实现半自动半人工或者自动为主人工为辅的方式。调试过程中发现, 如果要达到 95% 以上的查全率, 虚警率会提高接近 10 倍; 如果要把虚警率控制在一倍之内, 查全率则不足一半。通过多次试验与调试, 并与人工工作量对比分析, 综合考虑精度和效率, 本文认为 80% 左右的查全率、两三倍的虚警率可以在工程应用中发挥作用。至于图斑面积的查准率, 无论何种方式都难以到达理想状态。由于面积查准率不是该工程当前阶段的追求目标, 因此查

准率不做本次试验的重点要求。

通过多次试验和运算, 本文认为通州区和雁江区达到如下检测结果可以符合工程应用需求。具体检测结果见表 5 和表 6。

**表 5 通州区各类型精度统计表**  
**Tab. 5 Accuracy of different types based on TongZhou** (%)

图斑类型	数量查全率	数量虚警率	数量漏检率	面积查准率
1A	100.0	218.2	0.0	31.5
1B	83.5	109.1	16.5	16.9
1C	50.0	600.0	50.0	20.3
1D	44.4	500.0	55.6	14.9
1E	45.2	131.6	54.8	19.2
1F	28.6	1 400.0	71.4	25.3
2	76.1	116.0	23.9	15.9
3A	100.0	85.7	0.0	27.8
3B	67.0	307.5	33.0	16.3
3D	33.3	950.0	66.7	16.8
3E	41.7	720.0	58.3	29.7
3F	33.3	2 600.0	66.7	18.3
7A	93.8	183.3	6.3	24.5
7B	82.4	431.5	17.6	9.3
7D	50.0	3 000.0	50.0	37.0
合计	75.9	212.1	24.1	17.2

**表 6 雁江区试验结果统计表**  
**Tab. 6 Accuracy of different types based on YanJiang** (%)

图斑类型	数量查全率	数量虚警率	数量漏检率	面积查准率
1A	80.0	375.0	20.0	17.7
1B	85.7	265.0	14.3	12.9
1D	50.0	600.0	50.0	8.4
1E	0.0	400.0	100.0	0.0
2	69.8	516.7	30.2	16.7
3A	100.0	500.0	0.0	23.4
3B	90.0	118.5	10.0	18.7
3D	100.0	1 300.0	0.0	25.0
7A	83.3	325.0	16.7	8.1
7B	66.7	500.0	33.3	17.1
合计	82.6	309.6	17.4	15.9

从表 5 和表 6 可知, 新增建设用地图斑总体查全率分别为 75.9% 和 82.6%, 但不同类型的查全率差异较大, 对于非常明显的 1A/3A 类建设用地基本都能检测出来, 但对于规模较小、建设特征不太明显的其他建设用地图斑查全率则较低, 个别类型不足 50%。较测试样本而言, 通州和雁江区自动检测出的新增建设用地图斑虚警率更高, 2 个区县均检测出 2 倍以上的虚警率, 尤其是雁江区, 查全率越高, 虚警率越高。尽管从图斑个数方面查全率能够达到 70% ~ 80% 的精度, 但面积查准率较低, 两个区县均不足 20%。

## 5 结论与展望

本文结合全国土地利用遥感监测工程的实际需求,尝试利用深度学习对新增建设用地变化进行检测,并与人工目视判读的提取结果进行对比分析。试验表明,相较于传统的自动分类和变化检测方法,深度学习技术在新增建设用地变化提取方面有更高的适用性和实用性,并且具有较好的应用预期。通过试验主要得出以下几点结论:

1)大量的具有代表性的训练样本是深度学习技术的根本,全国土地利用遥感监测工程积累了几百万个新增建设用地样本,如继续深入训练,可大大提高自动检测精度。

2)地形地貌的差异对基于深度学习的自动检测结果影响不是很大,但新增建设用地类型不同自动提取结果差异较大。这与深度学习技术对训练样本代表性要求相吻合。

3)尽管本文试验结果与工程实际需求仍有一定的差距,可能与样本数量不够有关系,但如果以此为线索,辅以少量的人工后处理可有效提高工程实施效率,本年度工程实施过程中拟逐步推广应用。全国土地利用遥感监测工程时间要求紧、数据源众多、数据质量差异大、分类体系复杂多样,要全面达到理想状态难以实现。本文试验只是深度学习技术在土地利用遥感监测领域的初步探索,从相对单一的新增建设用地类型出发,逐步拓展到全地类提取,希望通过试验与应用能带动行业技术创新和发展,为解脱人工目视判读,提高工程科技含量奠定基础,下一步将扩大训练样本数量继续深入探索。

### 参考文献 (References):

[1] Hinton G E, Salakhutdinov R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504 - 507.

[2] Mnih V, Hinton G E. Learning to detect roads in high resolution aerial images[C]//Proc. of 2010 European Conf. Computer Vision (ECCV2010). Piscataway, NJ: IEEE, 2010: 210 - 223.

[3] 刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. 光学学报, 2016(4): 306 - 314.

Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning[J]. Acta Optica Sinica, 2016(4): 306 - 314.

[4] 高常鑫, 桑农. 基于深度学习的高分辨率遥感影像目标检测[J]. 测绘通报, 2014(s1): 108 - 111.

Gao C X, Sang N. Deep learning for object detection in remote sensing image[J]. Bulletin of Surveying and Mapping, 2014(s1):

108 - 111.

[5] 韩洁, 李盛阳, 张涛. 基于深度学习的遥感影像城市扩展方法研究[J]. 载人航天, 2017, 23(3): 414 - 419.

Han J, Li S Y, Zhang T. Research on urban expansion method based on deep learning of remote sensing image[J]. Manned Spaceflight, 2017, 23(3): 414 - 419.

[6] 张鑫龙, 陈秀芳, 李飞, 等. 高分辨率遥感影像的深度学习变化检测方法[J]. 测绘学报, 2017, 46(8): 999 - 1008.

Zhang X L, Chen X W, Li F, et al. Change detection method for high resolution remote sensing images using deep learning[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(8): 999 - 1008.

[7] 阚希, 张永宏, 曹庭, 等. 利用多光谱卫星遥感和深度学习方法进行青藏高原积雪识别[J]. 测绘学报, 2016, 45(10): 1210 - 1221.

Kan X, Zhang Y H, Cao T, et al. Snow cover recognition for Qinghai - Tibetan Plateau using deep learning and multispectral remote sensing[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(10): 1210 - 1221.

[8] 陈洋, 范荣双, 王竞雪, 等. 基于深度学习的资源三号卫星遥感影像云检测方法[J]. 光学学报, 2018, 38(1): 354 - 359.

Chen Y, Fan R S, Wang J X, et al. Cloud detection of ZY - 3 satellite remote sensing images based on deep learning[J]. Acta Optica Sinica, 2018, 38(1): 354 - 359.

[9] 朱祺夫, 赵俊三, 陈磊士, 等. 基于深度学习的遥感影像城市建筑用地提取[J]. 软件导刊, 2018, 17(10): 18 - 21.

Zhu Q F, Zhao J S, Chen L S, et al. Urban construction land extraction of the remote sensing image based on depth learning[J]. Software Guide, 2018, 17(10): 18 - 21.

[10] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300 - 1312.

Chang L, Deng X M, Zhou M Q. Convolutional neural networks in image understanding[J]. Acta Automatica Sinica, 2016, 42(9): 1300 - 1312.

[11] 朱寿红, 王胜利, 舒帮荣. 基于深度学习的高光谱遥感影像分类[J]. 城市勘测, 2017(4): 84 - 88.

Zhu S H, Wang S L, Shu B R. Classification of hyperspectral remote sensing image based on deep learning[J]. Urban Geotechnical Investigation & Surveying, 2017(4): 84 - 88.

[12] 余凯, 贾磊, 陈宇强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799 - 1804.

Yu K, Jia L, Chen Y Q, et al. Yesterday, today and tomorrow of deep learning[J]. Computer Research and Development, 2013, 50(9): 1799 - 1804.

[13] 郭丽丽, 丁世飞. 深度学习研究进展[J]. 计算机科学, 2015, 42(5): 28 - 33.

Guo L L, Ding S F. Research progress of deep learning[J]. Computer Science, 2015, 42(5): 28 - 33.

[14] 黄昕. 高分辨率遥感影像多尺度纹理、形状特征提取与面向对象分类研究[D]. 武汉: 武汉大学, 2009: 71 - 76.

Huang X. Multiscale Texture and Shape Feature Extraction and Object - oriented Classification for Very High Resolution Remotely Sensed Imagery[D]. Wuhan: Wuhan University, 2009: 71 - 76.

- [15] Hinton G. A practical guide to training restricted Boltzmann machines[J]. Momentum,2010,9(1):926.
- training deep neural networks[J]. Journal of Machine Learning Research,2009,10(1):1-40.
- [16] Larochelle H,Bengio Y,Louradour J,et al. Exploring strategies for

## Research on new construction land information extraction based on deep learning: Innovation exploration of the national project of land use monitoring via remote sensing

WU Haiping<sup>1</sup>, HUANG Shicun<sup>2</sup>

(1. *Institute of China Land Surveying and Planning, Beijing 100035, China*; 2. *China Center for Resources Satellite Data and Application, Beijing 100094, China*)

**Abstract:** The national project of land use monitoring via remote sensing has created millions of samples of new construction land. Based on these data, the authors conducted a preliminary research on applying the deep learning technology to automatically detect new constructions in comparison with the results generated by specialists. This study demonstrates that the deep learning technology has a great potential for completing the task of monitoring land use via remote sensing. It is believed that the efficiency of the project would be increased dramatically with minor manual assistance when a recall accuracy reaches 80%.

**Keywords:** deep learning; land use; remote sensing monitoring; new construction land

(责任编辑:李瑜)