

引用格式: Zhu Yinuo, Gao Ting, Wang Shudong, *et al.* Automatic Recognition Method of Construction Waste based on Transfer Learning and Retraining Model and High-score Remote Sensing Data[J]. Remote Sensing Technology and Application, 2021, 36(2): 314-323. [祝一诺, 高婷, 王术东, 等. 基于迁移学习再训练模型和高分遥感数据的建筑垃圾自动识别方法[J]. 遥感技术与应用, 2021, 36(2): 314-323.]
doi:10.11873/j.issn.1004-0323.2021.2.0314

基于迁移学习再训练模型和高分遥感数据的 建筑垃圾自动识别方法

祝一诺¹, 高婷¹, 王术东¹, 周磊^{1,2}, 杜明义^{1,2}

(1. 北京建筑大学 测绘与城市空间信息学院, 北京 102616;

2. 北京建筑大学 北京未来城市设计高精尖创新中心, 北京 100044)

摘要: 目前城市建筑垃圾大量持续产生且堆积严重, 利用率较低同时危害城市生态环境。建筑垃圾的识别是实现建筑垃圾分割、提取以及监测的技术基础, 但由于建筑垃圾本身的复杂特征和遥感影像的尺度差异、光谱差异等因素导致其识别和监管困难。提出了一种利用迁移学习再训练模型来实现自动识别建筑垃圾的方法。首先根据建筑垃圾的典型遥感特征构建样本库, 样本库包含30 292张建筑垃圾和110 110张典型地物在内的共计140 402张样本。之后基于国际先进的深度学习环境Tensorflow, 利用迁移学习在模型的最后一层重新输入了建筑垃圾等6类训练数据集, 对Inception-V3模型进行了再训练, 在较短时间内得到了建筑垃圾识别模型。随机抽取6 016张样本构成验证集逐个输入建筑垃圾识别模型, 统计验证样本的模型识别结果构成混淆矩阵, 得出该模型对所有地物的整体识别率 K 为97.43%, Kappa系数 Ka 为0.96, 模型识别建筑垃圾的识别精确度 P_c 为99.10%, 识别灵敏度为94.88%。与传统的航片监测、实地考察等纯人工识别方法相比, 该方法所需时间较短且识别精度较高, 有利于实现建筑垃圾的全过程实时监控和精准管理。

关键词: 高分遥感影像; 建筑垃圾; 迁移学习; 自动识别; Inception-V3

中图分类号: TP75 **文献标志码:** A **文章编号:** 1004-0323(2021)02-0314-10

1 引言

建筑垃圾指的是在建筑领域产生的固体垃圾, 确切地说, 它是在建造、更新以及拆除过程中产生的废物^[1]。目前我国每年产生的建筑垃圾约15.5~24亿t, 约占城市垃圾总量的40%^[2], 随着未来我国城市化进程的加快和大规模的城市建设及更新活动, 相伴产生的建筑垃圾将持续增多^[3]。

目前, 绝大部分建筑垃圾未经处理便被施工单位运往郊外或乡村露天堆放或填埋^[4], 这种粗放处理方式的弊端也十分明显。首先填埋1万t建筑垃

圾约占用667 m²的土地, 占用了大量土地资源^[5]; 其次由于建筑垃圾本身多样的种类和复杂的成分使得其在填埋和堆放的过程中会对水资源、大气甚至土壤造成极大的污染^[6]。除此之外, 这种处置方式的实际建筑垃圾资源化的利用率不足5%^[7], 与目前我国提倡的循环经济与可持续发展理念严重不符, 并且在像中国这样快速发展的新兴经济体中, 妥善管理建筑垃圾尤为紧迫, 因为在这些国家, 经济发展导致大规模建设, 而管理相关的废物的能力有所欠缺^[8]。因此如何快速识别建筑垃圾、合理高效地处理建筑垃圾已经成为政府部门和专家学者亟待

收稿日期: 2019-09-27; 修订日期: 2020-06-05

基金项目: 国家重点研发计划课题(2018YFC0706003), 北京市教委科技计划项目(KM201810016014)资助。

作者简介: 祝一诺(1999-), 女, 河南安阳人, 本科生, 主要从事机器学习以及环境遥感研究。E-mail: zhuyanuo7@163.com

通讯作者: 周磊(1983-), 男, 山东临沂人, 博士, 副教授, 主要从事环境遥感、GIS时空大数据研究。E-mail: zhoulei@bucea.edu.cn

解决的问题,引起了众多专家学者的关注。

自1988年Bagher等^[9]利用航空遥感数据识别新泽西州的垃圾堆放点开始,之后又有许多学者基于遥感数据采用不同方式对垃圾场及建筑垃圾的识别进行了研究。吴文伟等^[10]利用航片,通过建立判读标志,对北京市固体废弃物的分布进行了识别。刘亚岚等^[11]借助航片数据,利用北京1号小卫星融合影像建立判读标志,通过人机交互方式判读识别北京市未知的非正规垃圾场。虽然航片分辨率比较高、识别能力强,但是由于成本高、获取周期较长,难以达到实时监测非正规垃圾场变化的要求^[11]。

高分遥感影像同时具有高分辨率、高辐射精度、高定位精度和快速姿态机动能力等特点,在土地利用动态监测、环境保护与监测等领域具有广泛的应用潜力^[12],同时高分遥感影像包含的丰富的纹理信息可以降低由于建筑垃圾本身的复杂光谱特征而带来的识别难度。近年来,随着一系列高分卫星的发射,使得利用高分遥感影像识别垃圾类地物成为了可能。秦海春等^[13]基于高分二号遥感影像数据,采用目视解译的方法对无锡市垃圾堆放点进行识别分析,精度较高但时间人力耗费过大。黄惠玲等^[14]利用K-Means聚类算法进行颜色聚类与识别,无需进行前期训练,可自动识别出砖块。Li等^[15]以1995~2017年HJ-1bced和Landsat TM/OLI遥感数据为数据源,基于归一化植被指数(NDVI)分析和回归分析,对赣南6个县稀土开采、土地破坏和恢复现状进行了分析,时空分布分析的结果具有较高的精度。以上研究的对象多为垃圾场或某一特定类别的建筑垃圾,选择建筑垃圾作为对象的研究较少。

1989年,Lecun等结合反向传播算法首次架构了卷积神经网络结构,并将CNN用以手写体数字的识别,证明了深层神经网络应用于图像识别的可行性^[16]。之后随着卷积神经网络的蓬勃发展,深度学习的应用领域愈加广泛,许多学者在将深度学习应用到遥感影像识别和分类领域做出了许多有益探索,与传统分类方法相比,取得了很好的分类效果。Rebecca等^[17]将随机森林算法与哨兵二号的遥感影像结合用于澳大利亚东南部不同火灾严重等级的识别分类,并绘制成图,其中对于未燃尽和极端严重等级火灾(全冠消耗量)的识别准确率高达95%以上,郑宗生等^[18]利用多景台云图数据构建了台风云图训练集和测试集,并基于迁移学习训练出

了台风预报模型T-typCNNs,验证精度可达91.134%。王鑫等^[19]提出一种改进的基于深度学习的高分辨率遥感图像分类算法,通过设计的7层CNN获取影像特征,并设计了一种逻辑分类器对图像进行分类。经测试,与传统基于深度学习的遥感图像分类方法相比,其准确率提高了8.66%,但算法效率仍需提高。Huang等^[20]提出一种基于深度反卷积神经网络(Deponvnet)的有监督建筑物提取方法。首先创建一个高质量的建筑物数据集,然后在一个公共的大型建筑数据集上预演一个深度反卷积网络,之后对模型的输出进行精细调整。在建筑数据集上的大量实验证明了所提出的方法具备有效性。但是,在预训练深度反卷积网络模型时,耗时较长^[21]。

本研究以“建筑垃圾”为研究对象,基于高分遥感影像创建建筑垃圾样本库,结合Inception-V3模型,利用迁移学习再训练数据对建筑垃圾进行识别,为全过程实时监测与智能管控建筑垃圾提供了一种新思路。

2 样本库的创建

研究采用的数据为高分二号卫星影像与Google Earth影像的混合数据集,其中高分二号(GF2)数据选取了2018年9月5日北京市大兴区部分地区卫星影像,影像包含城区和郊外等多种地形区域,由于该区域属于发展建设较快的城市,因此易于选取研究所需的建筑垃圾影像数据。其中,全色影像分辨率1 m,多光谱影像分辨率4 m,且该影像均已经过辐射校正。由于获取的卫星遥感影像覆盖有限,为了满足试验结果的质量要求,选用Google Earth提供的高分辨率卫星影像数据作为补充数据,它提供的影像分辨率可达到1 m甚至亚米级,它将十分丰富的地理数据叠加在一起,且数据不断更新,其提供的卫星影像能够充分满足本试验要求。建筑垃圾的训练集和测试集选用的区域包括北京市及其周边和深圳、上海等东南沿海发达城市;背景训练集中的房屋和道路训练集选用的区域是北京市及其周边地区,植被和水体的训练集选用的区域为黑龙江、吉林、辽宁、内蒙古、新疆、西藏、云南、广东、广西、湖北、河南、湖南、山东、山西、青海、安徽,裸地的训练集选用的区域包括新疆、西藏、内蒙古、宁夏、蒙古及一些非洲国家。

在识别选择建筑垃圾样本过程中,根据部分已

知垃圾堆放点的分布位置与影像特征^[22],可以建立起建筑垃圾堆放点在遥感影像图上的解译标志,主要的特征包括颜色、纹理、形状、尺寸以及地理位置等^[10]。另外,由于建筑垃圾本身的时间特性,在样本的选取过程中,还依据 Google Earth 上的时间轴,

通过观测同一地点不同时间的地物特征可确定由房屋拆迁留下的建筑垃圾。研究获取的建筑垃圾、房屋、植被、水体、裸地、道路的遥感影像截图分别为 1 375、1 370、1 000、860、775、1 000 张。图 1 为解译标志库部分训练样本。



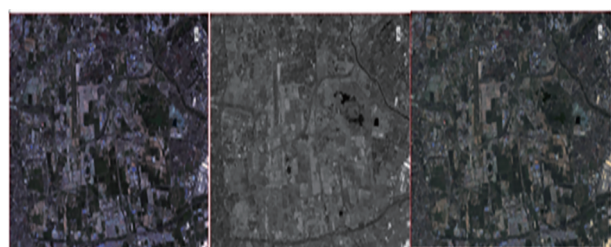
图 1 解译标志库部分训练样本

Fig.1 Part of training sample interpretation logo library

3 研究方法

3.1 图像预处理

高分二号遥感卫星影像分为多光谱(MSS)影像和全色(PAN)影像。多光谱影像具有较好的色彩,但分辨率较低,而全色影像有较高的分辨率,却缺乏色彩。为了得到可利用的研究数据,需要对影像数据进行预处理。预处理包括辐射校正、正射校正、图像配准和融合等,以此得到的融合数据兼备彩色和高分辨率的特性。选取波段 321 组合分别对应 RGB 对高分二号影像进行显示。处理前后遥感影像对比如图 2 所示。



(a) 多光谱影像 (b) 全色影像 (c) 融合后影像

图 2 处理前后遥感影像对比图

Fig.2 Contrast picture of remote sensing images before and after processing

融合过程在 ENVI5.3 中进行,采用 NNDiffuse Pan Sharpening 算法进行图像融合,此方法得到的结果对于色彩、纹理和光谱信息均能得到很好保

留,较其他融合方法更具优越性。最终得到 1 m 分辨率的多光谱彩色合成影像,输出数据类型为整型,以利于对建筑垃圾的识别和相关信息的提取。融合过程如图 3 所示。

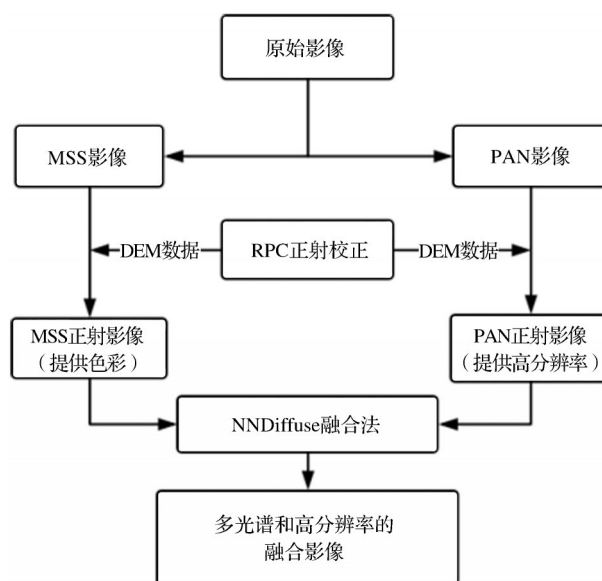


图 3 融合流程图

Fig.3 Sharpening flow chart

研究将地物分为两大类:正样本建筑垃圾和负样本典型地物,其中典型地物包括房屋、植被、水体、裸地、道路 5 类。由于 Inception-V3 模型在进行迁移学习时必须保证一个标签的输入数据仅含有一类

地物,而普通全景的遥感影像所包含的地物太过复杂,因此必须通过截图达到提取某一类特定地物的目的。又由于Inception-V3模型对于图片的尺寸有一定的要求,将样本集中的图片尺寸大致统一为了 224×224 像素。同时,为了保证迁移学习后识别模型的

精度,训练数据要尽可能多,并且同一类别的地物应该尽量包含该地物所具有的所有的不同特征^[23]。图4为建筑垃圾样本类型示例,其中图4(a)属于大面积的拆除建筑垃圾,图4(b)属于大面积的在建过程中产生的建筑垃圾,图4(c)则属于小型的建筑垃圾。

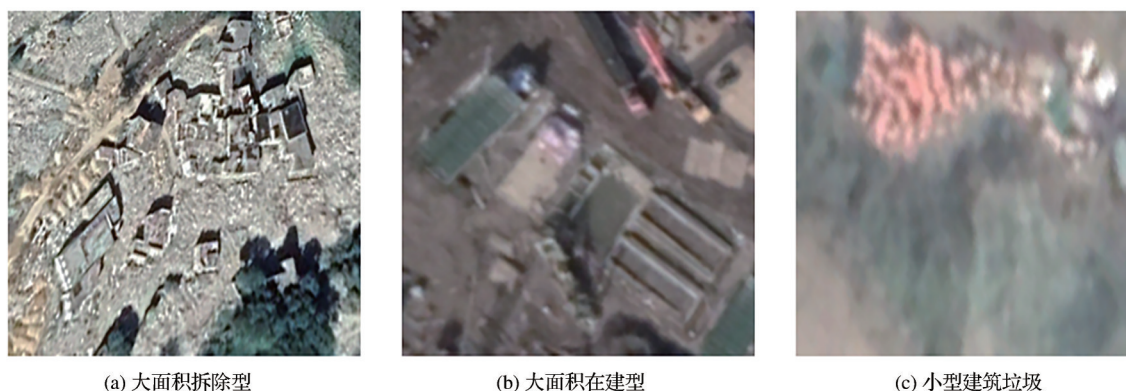


图4 建筑垃圾样本类型示例

Fig.4 Sample of different types of construction waste

3.2 数据增强

由于手工进行不同地物类别的截图效率太低,同时为了避免由于数据量过小而可能会造成的过拟合的问题,需要对原始数据进行数据增强。常用的数据增强方法有对颜色的数据增强、尺度变换、水平或垂直的反转、旋转或反射变换以及类别不平衡数据的增广等^[23]。

研究主要采用的数据增强方法是尺度和角度的变换,在建筑垃圾和典型地物遥感影像截图的基础上,对建筑垃圾、植被、水体、房屋、道路、裸地6类地物分别进行了7次角度变换(旋转 45° 、 90° 、 135° 、 180° 、 225° 、 270° 和 315°)和3次尺度变换(0.5、1、2倍),最终得到了每一类地物在原始数据量的基础上增强了21倍后的结果,数据量对比如图5所示。从图6可以看出数据增强大大提高了样本库中各类地物形态的多样性。

3.3 建筑垃圾自动识别方法

3.3.1 卷积神经网络与GoogLeNet模型

由于机器学习和深度学习方法与数据紧密相关,为适应当今大数据与更新快的特点,利用深度学习和机器学习对地物进行自动识别已经逐渐成为未来的发展方向。其中卷积神经网络模型由于共享权值、在快速自动处理数据的同时又能够取得较高识别精度等优势在图像识别领域占据了越来越重要的地位。

神经网络是由输入层、隐含层和输出层3层结

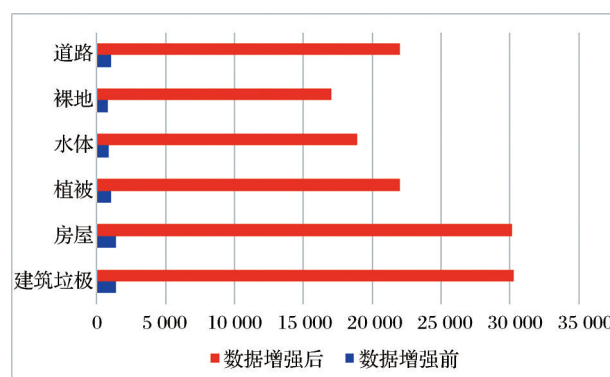


图5 数据增强前后各类地物数据量对比图

Fig.5 Contrast map of data volume of various ground objects before and after data enhancement

构构成的。而卷积神经网络(Convolutional Neural Network, CNN)相较于一般神经网络最突出的特征是增加了卷积层(conv layer)和池化层(pooling layer),其他层级结构仍与一般神经网络一致^[24]。卷积层的主要作用是提取特征,最先几层卷积层可能只能提取一些低级的特征,随着卷积层数的不断增加,更复杂的特征能被提取出来。而池化层,也叫下采样层,主要的目的是在保留有用信息的基础上减少数据处理量,加快训练网络的速度^[25]。得到卷积输出层的公式如下所示:

$$Cx = \int [f(X \cdot wx)] + bx \quad (1)$$

其中: X 表示特征图, wx 表示相应的卷积核, f 表示卷积函数, bx 为偏置, $[\cdot]$ 代表激励函数。整个卷积神经网络的基本架构如图7所示。

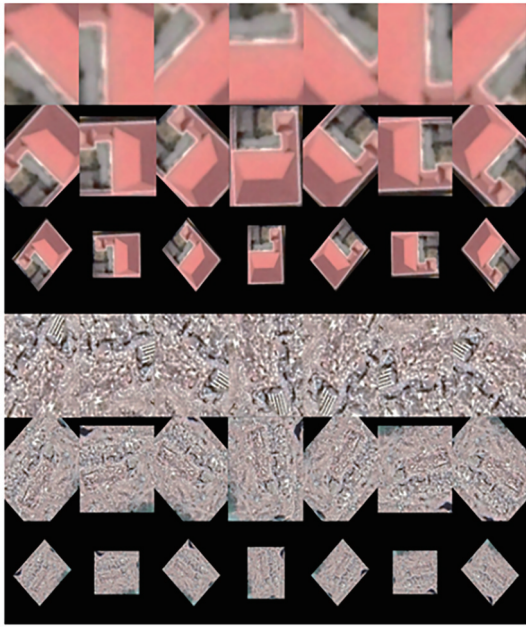


图 6 数据增强结果(以建筑垃圾和房屋为例)

Fig.6 Data enhancement results
(take construction waste and buildings for example)

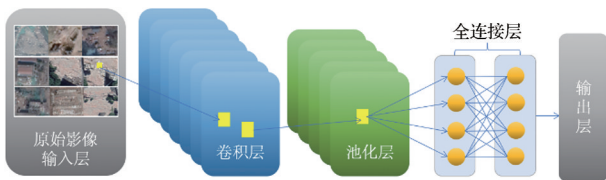


图 7 卷积神经网络基本结构图

Fig.7 Basic structure of CNN

GoogLeNet 由 Google 公司的 Deep Mind 团队于 2014 年提出,它引入了 Inception 结构解决了一般卷积神经网络容易出现的数据过拟合和耗费大量计算资源的问题。Inception 结构用密集成分来近似最优的局部稀疏结构,从而在保证网络结构稀疏性的同时又可以利用密集矩阵来提高计算资源的利用率。因此该模型在遥感图像场景分类任务中应用较为成功^[26]。

3.3.2 基于迁移学习的再训练模型

创建一个现代图像识别模型需要使用大量图像参数,因此在训练图像的过程中将会需要大量的训练数据和较长的计算机 GPU 运行时间,耗费大量计算资源且效率不高。迁移学习方法可保留原模型权重与偏置,仅从被修改层重新训练,可节约大量时间。首先保持模型最后一层前各层的参数,然后移除最后一层并输入数据集,仅重新训练最后一层便可以在较短时间内得到添加新的识别类别后的模型,大大简化了原本的图像训练过程^[27],具有

灵活性和高效性。

实验是基于 Tensorflow 平台的 Inception-V3 模型,利用迁移学习方法训练建筑垃圾的自动识别模型。Tensorflow 是在 Google 开发的国际先进的深度学习环境,具有高可用性和高灵活性的优点,并在其研究人员努力下不断地提高效率^[27-31]。Inception-V3 图像识别模型最初使用 2012 年的数据针对 ImageNet 大型视觉识别挑战赛训练而成,其识别结果的 top-5 错误率可以低至 3.46%,是一个功能强大且较为成熟的模型。

主要以北京市周边和深圳、上海等东南沿海发达城市的建筑垃圾高分二号影像和 Google earth 影像为研究对象,在遥感影像截取建筑垃圾训练样本的过程中,以建筑垃圾、房屋、植被、水体、裸地、道路六类遥感图像集作为将要训练的新类别。

接下来利用 Inception-V3 图像识别模型强大的图像特征提取组件来实现对将要训练的 6 类地物遥感图像集的特征提取。在这个过程中,Inception-V3 图像识别模型将完成对两类类别下的所有图像的分析,同时完成计算并缓存筛选出的所有 bottleneck 参数值。一张影像有成千上万个参数,而 Inception-V3 图像识别模型通过遍历所有目标图像,筛选出一些对于识别影像发挥重要作用的参数,以此来降低维度,减少所要检测的图像参数数目,对目标训练图像进行一个有效而简洁的总结,以此来实现对 6 类遥感图像集的特征提取。

在本研究中,模型随机选取样本集的 10% 作为测试集,10% 作为验证集。每 10 次训练后会对训练结果进行评估,其中测试集只用于最后训练结束后的最终模型精度评估,为保证模型运行过程中的结果更加稳定,测试集中的所有图片被使用。而验证集用于训练过程中的模型识别准确度的评估,其使用频率会远高于测试集,为加快模型的训练速度,每次只会随机选出验证集中的 100 张使用。脚本默认重复训练 4 000 次,每一次都会从训练样本集中随机选出一百张图像($N=100$)进行训练,这意味着每一张图像的 bottleneck 关键参数值都将会被重复使用多次,而训练和计算每一个瓶颈值会耗费很长时间。模型会自动对已计算图像的 bottleneck 关键参数值进行缓存,从而避免了重复计算使效率降低,保证了模型的高效性。网络参数设置如表 1 所示。

每训练 10 次,脚本将会输出训练准确度(train-

表 1 Inception-V3网络结构参数设置	
Table1 Parameter setting of inception-V3	
参数	数值
迭代次数	4 000
初始学习率	0.01
训练批量大小	100
测试批量大小	-1
验证批量大小	100
测试集比例	10%
验证集比例	10%
评估间隔	10

ing accuracy)、确认准确度(validation accuracy)和交叉熵(cross entropy),脚本会根据这 3 个结果对 bottleneck 关键参数在识别中所占的权重进行调整,从图 8 可以看出,随着训练次数的增多,训练准确度

和确认准确度在不断提高,在训练了 130 次后二者都趋于稳定并不断逼近 1,交叉熵随着训练次数的增多逐渐降低,在训练了 1 570 次后稳定在 0.16 附近。

3.4 模型验证方法

实验随机抽取建筑垃圾和典型地物样本库的 90% 作为训练集利用上文的迁移学习算法进行再训练获得建筑垃圾识别模型,其余 10% 用于随机抽样选取验证数据集,将各个类别验证数据集中的图片逐个输入模型以检验模型的识别效果。模型在对一张图片进行判读的时候会同时输出 6 个类别及其对应的匹配精度,选取匹配精度最高的地物类别作为模型对该图片的识别结果类别,总体的识别流程如图 9 所示。

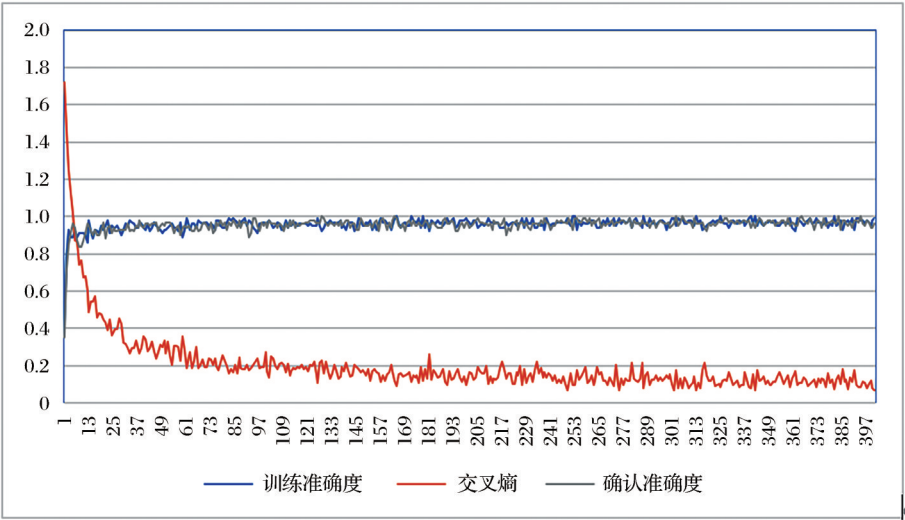


图 8 建筑垃圾识别模型训练曲线

Fig.8 Training curve of construction waste identification model

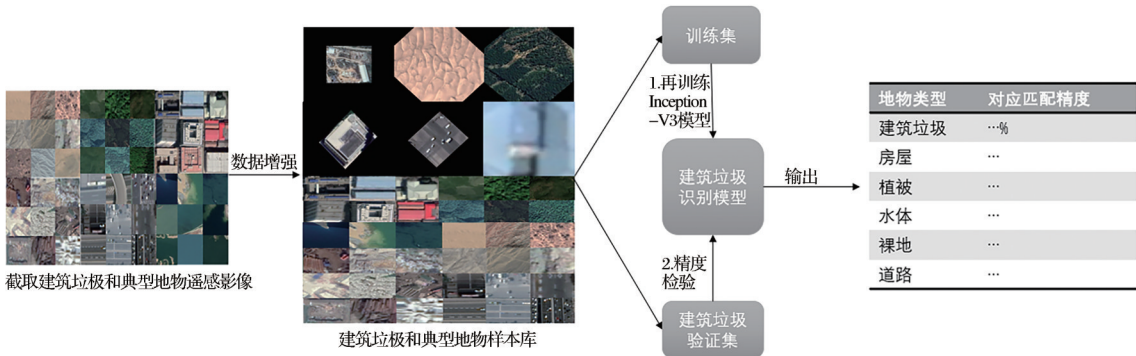


图 9 建筑垃圾自动识别技术流程图

Fig.9 Flow chart of automatic identification technology for construction waste

4 模型验证结果

实验采用的验证数据集由样本库随机选取获

得,包含建筑垃圾等本文提到的 6 类地物,其中房屋、植被、水体、道路、裸地每类地物的验证图片各 600 张,建筑垃圾验证图片 3 026 张。利用本文构建

的模型对验证数据集进行识别分类,记录模型对于每张图片的识别情况,统计获得如表2所示的混淆矩阵。

表2 模型识别效果混淆矩阵

Table2 Confusion matrix of model recognition effect

		真实值					
		建筑垃圾	水体	植被	道路	裸地	房屋
预测值	建筑垃圾	2 871	0	0	0	17	9
	水体	11	583	25	1	0	0
	植被	5	6	573	0	0	0
	道路	6	0	1	592	0	10
	裸地	99	11	1	0	583	2
	房屋	34	0	0	7	0	579

对于模型对包含建筑垃圾在内的典型地物的识别精度,本文采用整体识别率(K)和 Kappa 系数(Ka)进行评定,两个指标分别表示为:

$$K = \frac{T}{N} \quad (2)$$

$$Kappa = \frac{K - P_e}{1 - P_e} \quad (3)$$

其中: T 分别代表模型预测正确的图片数之和, N 为总的验证样本数。式(3)中 P_e 的计算方式为:

$$P_e = \frac{\sum a_i \times b_i}{N^2} \quad (4)$$

其中: a_i 为每类地物的真实样本数, b_i 为模型预测的每类地物的样本数。

为细化模型对于建筑垃圾的识别效果,对其进行更加直观的评价,本文将表2中的混淆矩阵简化为二分类矩阵,即类别中只包含建筑垃圾和非建筑垃圾的矩阵,如表3所示。

表3 模型识别效果二分类矩阵

Table3 Binary classification matrix of model recognition effect

真实值 预测值	建筑垃圾	非建筑垃圾
建筑垃圾	2 871	26
非建筑垃圾	155	2 974

本文采用识别精确率(P_v)和识别灵敏度(T_r)两个指标对模型识别建筑垃圾的精度进行评定,两个指标分别表示为:

$$P_v = \frac{T_c}{(T_c + F_c)} \quad (5)$$

$$T_r = \frac{T_c}{(T_c + F_n)} \quad (6)$$

其中: T_c 表示样本的真实类别是建筑垃圾(正类),并且模型预测的结果也是建筑垃圾(正类)的图片数, F_c 为样本的真实类别是非建筑垃圾(负类),模型预测的结果是建筑垃圾(正类)的图片数;式(6)中的 F_n 为样本的真实类别是建筑垃圾(正类),模型预测的结果是非建筑垃圾(负类)的图片数。

经过数据分析,模型对所有地物的整体识别率 K 为97.43%, Kappa系数 Ka 为0.96,模型识别建筑垃圾的识别精确度 P_v 为99.10%,识别灵敏度为94.88%。上述指标表明本文构建的模型能够准确地识别出建筑垃圾,在典型地物图片的分类识别方面也有较好的表现。

从表2中可以看出模型对于建筑垃圾的识别上存在很小的错分。为进一步探究错分的原因,本文对错分图片和对应错分类别的典型图片进行了对比,从图10可以看出错分主要是由于两种类别的某些图片在在纹理、色彩上相似程度较高而导致的。在建筑垃圾验证集中,分别有99张和34张错分为裸地与房屋,高于本文中其他非建筑垃圾的地物。由于裸地和房屋与建筑垃圾在纹理、色彩上与建筑垃圾及其相似,容易造成模型的错分,而植被、水体、道路在纹理、色彩上与建筑垃圾的相似程度明显小于前两者,后三者的总错分率远小于前两者。

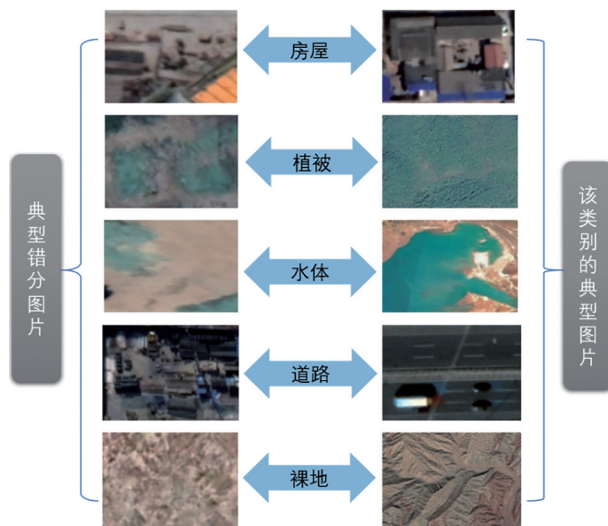


图10 错分典型图片示例

Fig.10 Example of typical misclassified pictures

5 讨 论

随着城市化进程的加快,建筑垃圾产量巨大且持续增加^[3],其对于城市环境的多方面危害^[6]使构建建筑垃圾自动识别和监测体系迫在眉睫。但建筑垃圾包含多种废弃物^[32]、光谱特征复杂增加了其

识别和监管的难度,且目前的研究多针对与建筑垃圾在光谱和形态较为相似的垃圾场^[13],或仅针对某一特定类别的建筑垃圾^[14],单独以建筑垃圾为研究对象的研究较少,也造成了其样本不足,识别方法有待探索的局面。针对这些问题,首先构建了包含建筑垃圾在内的典型地物机器学习训练样本库,是在现有针对建筑垃圾研究较少的情况下对地物训练样本库的补充;同时提出了一种利用迁移学习再训练模型来实现自动识别建筑垃圾的方法并进行了实验,实验结果证明了识别方法的可行性和样本库的可靠性。作为整个建筑垃圾识别体系的初级阶段,本研究只局限于建筑垃圾的自动识别,同时也为后续建筑垃圾的自动分割、提取和监测奠定了基础。

6 结 论

建筑垃圾因其日益严重的堆积问题为生态环境带来了极大风险,而目前国内对于建筑垃圾的研究仍处于初步阶段,选择建筑垃圾作为研究对象提出的识别方法较少,对于建筑垃圾的识别主要停留在实地考察和目视解译阶段,耗费大量人力物力且无法满足政府和社会对于实现实时监测和管控大量建筑垃圾、建立建筑垃圾天地一体化快速识别技术体系与监测系统的需求。本研究构建的包含建筑垃圾在内的典型地物机器学习训练样本库和提出的高分遥感建筑垃圾的自动识别方法是进一步实现建筑垃圾图像自动分割和提取的技术基础。相对于目前建筑垃圾的识别方法,基于迁移学习再训练模型的建筑垃圾自动识别方法主要有以下3点优势:①节约时间和人力。该识别方法只需前期人工解译少数建筑垃圾影像构建训练样本库,在CPU为 Intel(R) Xeon(R) Gold 5122 CPU @ 3.60GHz 3.59GHz (2 处理器);GPU 为 NVIDIA Quadro P5000 16 GB GDDR5X;内存 64 G CPU 的惠普 Z8 G4 高性能图形工作站上训练4~5小时即可获得模型;批量输入图片后模型会自动识别并输出匹配精度。②可靠性。在训练样本充足且质量较好的情况下,模型识别建筑垃圾的识别精确度 P_v 可以达到99.10%,识别灵敏度可以达到94.88%。③模型可以较容易地实现更新与改进。后续可以通过更新本研究构建的包含建筑垃圾等6类地物在内的机器学习训练样本库对模型进行不断地完善,使模型适应各类新形态的建筑垃圾。同时,研究成果仍存

在一定的局限性:①模型的识别精度受限于用于训练的遥感影像分辨率,由于样本分辨率不高,建筑垃圾的纹理和色彩与其他类别例如房屋和裸地的区别不够明显,容易导致类别的错分。②本文所构建的建筑垃圾样本库在样本数量和样本多样性上仍存在较大的提高空间,有望通过后续进一步扩大研究区域进行优化。

本文提出的建筑垃圾识别方法是构建建筑垃圾天地一体化快速识别技术体系第一步,后续将基于该研究成果实现建筑垃圾的边界确定、自动分割和提取以及监测,进一步实现建筑垃圾的快速识别、定位、空地结合的精准估算和建筑垃圾动态监测,解决传统单一监测手段无法快速、准确获取建筑垃圾类型、面积、体量等动态变化信息的问题,最终目标是构建建筑垃圾天地一体化快速识别技术体系与监测系统。

参考文献(References):

- [1] Ministry of Housing and Urban Rural Development of the People's Republic of China. GB 50009-2012 Load Code for Building Structures [S]. Beijing: China Architecture & Building Press, 2012. [中华人民共和国住房和城乡建设部. GB 50009-2012 建筑结构荷载规范[S]. 北京: 中国建筑工业出版社, 2012.]
- [2] Strategic Alliance for Technological Innovation of China's Construction Waste Resource Industry. Report on the Development of China's Construction Waste Resource Industry[R]. Beijing: 2014. [中国建筑垃圾资源化产业技术创新战略联盟. 中国建筑垃圾资源化产业发展报告[R]. 北京: 2014.]
- [3] Zhao Jun, Liu Qiuxia, Lin Liqing, et al. Evolution and Comparison of Construction Waste Generation Characteristics in Big Cities [J]. Journal of Central South University (Natural Science Edition), 2013, 44(3): 1297-1304. [赵军, 刘秋霞, 林立清, 等. 大城市建筑垃圾产生特征演变及比较[J]. 中南大学学报(自然科学版), 2013, 44(3): 1297-1304.]
- [4] Lu Zhongyi. Exploration on the Utilization of Urban Construction Waste [J]. Shanxi Architecture, 2019, 45(6): 183-184. [卢忠义. 城市建筑垃圾资源化利用探讨[J]. 山西建筑, 2019, 45(6): 183-184.]
- [5] Yang X N. Study on Environmental Impact Assessment of Construction Waste [J]. Chemical Intermediate, 2015, 11(10): 109-110. [杨小宁. 关于建筑垃圾的环境影响评价研究[J]. 化工中间体, 2015, 11(10): 109-110.]
- [6] Li Yilong. Brief Analysis of Environmental Pollution Hazards and Management Measures of Construction Waste under the Background of Urbanization [J]. Green Building Materials, 2018(3): 19-20. [李熠龙. 浅析城镇化背景下建筑垃圾对于环境的污染危害及管理措施[J]. 绿色环保建材, 2018(3):

- 19-20.]
- [7] He Jiayan. Beijing Speeds up the Recycling of Construction Waste [J]. Invest in Beijing, 2018(6): 35-36.[何佳艳. 北京提速建筑垃圾资源化处理[J]. 投资北京, 2018(6): 35-36.]
- [8] Zhikang B, Weisheng L. Developing Efficient Circularity for Construction and Demolition Waste Management in Fast Emerging Economies: Lessons Learned from Shenzhen, China [J]. Science of the Total Environment, 2020, 724. doi: 10.1016/j.scitotenv.2020.138264.
- [9] Bagheri S, Hordon R M. Hazardous Waste Site Identification Using Aerial Photography: A Pilot Study in Burlington County, New Jersey, USA [J]. Environmental Management, 1988, 12(3): 411-412. doi: 10.1007/BF01867531.
- [10] Wu Wenwei, Liu Jing. Application of Remote Sensing Technology in the Investigation of Solid Waste Distribution in Beijing [J]. Environmental Health Engineering, 2000(2): 76-78. [吴文伟, 刘竞. 北京市固体废弃物分布调查中遥感技术的应用[J]. 环境卫生工程, 2000(2): 76-78.]
- [11] Liu Yalan, Ren Yuhuan, Wei Chengjie, *et al.* Applied Research on the Monitoring of Irregular Garbage Dumps by Beijing No. 1 Small Satellite [J]. Journal of Remote Sensing, 2009, 13(2): 320-326.[刘亚岚, 任玉环, 魏成阶, 等. 北京 1 号小卫星监测非正规垃圾场的应用研究[J]. 遥感学报, 2009, 13(2): 320-326.]
- [12] Liang W H, Liu J K, Chen Q, *et al.* Comparative Analysis of Extraction of Eucalyptus Information from GF-2 Image based on Object-oriented Method [J]. Forestry Resource Management, 2017(6): 54-59.[梁文海, 刘吉凯, 陈琦等. 基于面向对象方法的 GF-2 影像按树信息提取对比分析[J]. 林业资源管理, 2017(6): 54-59.]
- [13] Qin Haichun. Research on Urban Domestic Refuse Monitoring Method based on High-resolution Remote Sensing Images Made in China [J]. China Construction Informatization, 2016(4): 75-77.[秦海春. 基于国产高分遥感影像的城镇生活垃圾监管方法研究[J]. 中国建设信息化, 2016(4): 75-77.]
- [14] Huang Huiling, Han Jun, Wu Feibin, *et al.* Study on Color Feature Extraction and Classification of Construction Waste [J]. Optical and Optoelectronic Technology, 2018, 16(1): 53-57.[黄惠玲, 韩军, 吴飞斌, 等. 建筑垃圾的颜色特征提取与分类研究[J]. 光学与光电技术, 2018, 16(1): 53-57.]
- [15] Li H K, Xu F, Li Q. Remote Sensing Monitoring of Land Damage and Restoration in Rare Earth Mining Areas in 6 Counties in Southern Jiangxi based on Multisource Sequential Images [J]. Journal of Environmental Management, 2020, 267. doi:10.1016/j.jenvman.2020.110653.
- [16] Lecun Y, Boser B, Denker J S, *et al.* Backpropagation Applied to Handwritten Zip Code Recognition [J]. Neural Computation, 1989, 1(4): 541-551. doi:10.1162/neco.1989.1.4. 541.
- [17] Rebecca G, Tim D, Warwick H, *et al.* A Remote Sensing Approach to Mapping Fire Severity in South-eastern Australia Using Sentinel 2 and Random Forest [J]. Remote Sensing of Environment, 2020, 240. doi: 10.1016/j.rse.2020.111702.
- [18] Zheng Zongsheng, Hu Chenyu, Huang Dongmei, *et al.* Research on Transfer Learning Methods for Classification of Typhoon Cloud Image [J]. Remote Sensing Technology and Application, 2020, 35(1): 202-210.[郑宗生, 胡晨雨, 黄冬梅, 等. 基于迁移学习及气象卫星云图的台风等级分类研究[J]. 遥感技术与应用, 2020, 35(1): 202-210.]
- [19] Wang Xin, Li Ke, Xv Mingjun, *et al.* An Improved Remote Sensing Image Classification Method based on Depth Learning [J]. Computer Applications, 2019, 32(2): 382-387.[王鑫, 李可, 徐明君, 等. 改进的基于深度学习的遥感图像分类方法[J]. 计算机应用, 2019, 32(2): 382-387.]
- [20] Huang Z M, Cheng G L, Wang H Z, *et al.* Building Extraction from Multi-source Remote Sensing Images via Deep Deconvolution Neural Networks [C]//IEEE International Geoscience and Remote Sensing Symposium. Beijing, 2016. doi: 10.1109/IGARSS.2016.7729471.
- [21] Zheng Yuanpan, Li Guangyang, Li Ye. Review on the Application of Deep Learning in Image Recognition [J]. Computer Engineering and Applications, 2019, 55(12): 20-36.[郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J]. 计算机工程与应用, 2019, 55(12): 20-36.]
- [22] Lin Y Z, Zhang B M, Xu J F, *et al.* Building Extraction from High Resolution Remote Sensing Images based on Multi-features and Multi-scales [J]. Surveying and Mapping Bulletin, 2017(12): 53-57.[林雨准, 张保明, 徐俊峰, 等. 多特征多尺度相结合的高分辨率遥感影像建筑物提取[J]. 测绘通报, 2017(12): 53-57.]
- [23] Gao Yang. Building Extraction from High Resolution Remote Sensing Images based on Convolutional Neural Network [D]. Nanjing: Nanjing University, 2018.[高扬. 基于卷积神经网络的高分辨率遥感影像建筑物提取[D]. 南京: 南京大学, 2018.]
- [24] Yang Zhenzhen, Kuang Nan, Fan Lu, *et al.* An Overview of Image Classification Algorithms based on Convolutional Neural Networks [J]. Signal Processing, 2018, 34(12): 1474-1489.[杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12): 1474-1489.]
- [25] Wu Zhengwen. Application of Convolutional Neural Network in Image Classification [D]. Chengdu: University of Electronic Science and Technology, 2015.[吴正文. 卷积神经网络在图像分类中的应用研究[D]. 成都: 电子科技大学, 2015.]
- [26] Zhao Xujiang. Remote Sensing Image Target Detection and Recognition based on Convolution Neural Network [D]. Beijing: China University of Science and Technology, 2018.[赵旭江. 基于卷积神经网络的遥感图像目标检测与识别[D]. 北京: 中国科学技术大学, 2018.]
- [27] Lin Yu, Chen Xiaoyong. Research on Road Traffic Sign Recognition based on Inception V3 Model [J]. Jiangxi Science, 2018, 36(5): 849-852.[林宇, 陈晓勇. 基于 Inception V3 模型的道路交通标志识别研究[J]. 江西科学, 2018, 36(5): 849-852.]
- [28] Abadi M, Agarwal A, Barham P, *et al.* Tensor Flow: Large-

- Scale Machine Learning on Heterogeneous Distributed Systems[J]. Preliminary White Paper, 2016, 9: 1-19.
- [29] Saxena A. Convolutional Neural Networks: An Illustration in Tensor Flow [J]. Crossroads, 2016, 22 (4): 56-58. doi: 10.1145/2951024.
- [30] Szegedy C, Vanhoucke V, Ioffe S, *et al.* Rethinking the Inception Architecture for Computer Vision[J]. Computer Science, 2015: 2818-2826. doi:10.1109/CVPR.2016.308.
- [31] Angelova A, Zhu S. Efficient Object Detection and Segmentation for Fine-grained Recognition [J]. IEEE Conference on Computer Vision and Pattern Recognition, 2013: 9(4): 811-81. doi: 10.1109/cvpr.2013.110.
- [32] Lu K A. Current Situation and Comprehensive Utilization of Construction Waste in China [J]. Construction Technique, 2005, 28(6): 15-16. [陆凯安. 我国建筑垃圾的现状与综合利用[J]. 施工技术, 2005, 28(6): 15-16.]

Automatic Recognition Method of Construction Waste based on Transfer Learning and Retraining Model and High-score Remote Sensing Data

Zhu Yinuo¹, Gao Ting¹, Wang Shudong¹, Zhou Lei^{1,2}, Du Mingyi^{1,2}

(1.School of Geomatics and Urban Spatial Informatics, Beijing University of Civil Engineering and Architecture, Beijing 102616, China;

2.Beijing Advanced Innovation Center for Future Urban Design, Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract: At present, a quantity of urban construction waste is constantly produced and seriously accumulated, and its utilization rate is low, which endanger the urban ecological environment. The recognition of construction waste is the technical basis for the segmentation, extraction and monitoring of construction waste. However, it is difficult to identify and monitor construction waste due to its complex characteristics, the scale difference and spectral difference of remote sensing image. In this paper, a method of automatic identification of construction waste based on transfer learning and retraining model is proposed. Firstly, a sample bank is constructed according to the typical remote sensing features of construction waste. Then, based on the advanced international deep learning environment Tensorflow, the Inception-V3 model is retrained by using transfer learning, and the recognition model of construction waste is obtained. After verification, the overall recognition accuracy of construction waste can reach 94.88%. Compared with the traditional manual identification methods such as aerial photo monitoring and field investigation, the method studied in this paper has higher efficiency and recognition accuracy, which can provide a technical basis for real-time monitoring and accurate management of construction waste in the whole process.

Key words: High-resolution remote sensing image; Construction waste; Transfer learning; Automatic recognition; Inception-V3