

引用格式: Li Qing, Chen Junjie, Li Qingting, *et al.* Detection of Tailings Pond in Beijing—Tianjin—Hebei Region based on SSD Model[J]. Remote Sensing Technology and Application, 2021, 36(2): 293–303. [李庆, 陈俊杰, 李庆亭, 等. 基于SSD模型的京津冀地区尾矿库检测[J]. 遥感技术与应用, 2021, 36(2): 293–303.]
doi:10.11873/j.issn.1004-0323.2021.2.0293

基于SSD模型的京津冀地区尾矿库检测

李 庆^{1,2}, 陈俊杰¹, 李庆亭², 李柏鹏², 卢凯旋², 咎露洋², 陈正超²

(1. 河南理工大学测绘与国土信息工程学院, 河南 焦作 454000;

2. 中国科学院空天信息创新研究院, 北京 100094)

摘要:我国尾矿库事故频发,所造成的危害极其严重。掌握尾矿库的数量及分布情况对预防尾矿库事故和开展尾矿库应急工作具有重大意义。传统的调查方法主要以地面调查为主,难以做到大范围高频次的监测。因此提出了一种基于深度学习的尾矿库目标检测方法,可以快速识别尾矿库的位置并掌握其地理分布。首先分析尾矿库在遥感图像上的特征,制作适合训练的样本,根据样本的情况优化调整训SSD (Single Shot Multibox Detector)模型,基于优化后的模型进行京津冀地区尾矿库的自动提取。实验结果表明:京津冀地区检测出尾矿库2 696座,召回率达到93.3%。说明采用深度学习目标检测的方法提取尾矿库,取得了较好的效果,所提出的尾矿库提取方法可应用于全国及全球尾矿库的提取。

关键词:遥感;深度学习;目标检测;尾矿库;京津冀

中图分类号:P237 **文献标志码:**A **文章编号:**1004-0323(2021)02-0293-11

1 引 言

尾矿库是指由筑坝拦截谷口或围地围成的,用以堆放金属或非金属矿山矿石分选后排出的尾矿、湿法冶炼产生的废物或其他工业废渣的场所^[1]。据不完全统计,我国现有矿山15.3万座,截至2012年底,全国共有尾矿库12 273座,集中分布在我国华北、东北、华中地区。根据尾矿库安全状况划分,全国有危库54座,险库100座,病库1 069座^[2]。一部分尾矿库存在较多问题,安全隐患大,治理难度增大。近年来,由于各种自然和人为等原因,我国尾矿库事故频发,所造成的危害极其严重,为了有效地预防尾矿库事故,积极开展尾矿库应急工作,有必要摸清尾矿库存在状况。

尾矿库不仅分布范围广,数量巨大,而且尾矿库的监测对时效性有很高的要求。遥感技术具有

探测范围广、获取资料数据快、受地面条件限制少、获取数据量大等优点,可以很好地弥补地面人工监测方法的不足,是尾矿库监测的有效技术手段^[3]。许多科研工作者借助遥感图像对尾矿库进行了监测及其环境影响的分析。郝利娜等^[4]利用高分辨率遥感图像对鄂东南尾矿库结构特征、分布特征、光谱特征、纹理特征进行了分析;强建华^[5]利用SPOT 5、RAPIDEYE等卫星遥感数据解译陕西省尾库矿库分布情况;肖如林等^[6]对张家口区域的遥感图像进行分割,借助人工目视解译的方法调查出张家口市尾矿库的分布情况;王创业等^[7]利用QucikBird高分辨率遥感影像,分析了尾矿以及固体废物的光谱特性以及空间几何特征,确定单个尾矿库的分割阈值,实现了对尾矿库的分割解译;周英杰等^[8]利用我国高分辨率遥感图像解译出山东省内尾矿库的分布,并定性分析了这些尾矿库的分布范围以及潜在

收稿日期:2019-11-02;修订日期:2021-03-16

基金项目:国家自然科学基金项目(42071407)资助。

作者简介:李 庆(1994—),男,安徽池州人,硕士研究生,主要从事摄影测量与遥感技术方面的研究。E-mail:1104411435@qq.com

通讯作者:陈正超(1976—),男,河南信阳人,博士,研究员,硕士生导师,主要从事定标与真实性检验、图像处理与质量评价、遥感大数据智能信息提取等研究。E-mail:chenzc@radi.ac.cn

危害。总体上看,目前借助遥感技术基本实现了对尾矿库的分布监测和分析,但获取尾矿库的位置、数量等信息主要是通过人工目视解译完成的,这种方法主观性强,速度较慢,无法实现大范围内尾矿库的自动快速提取。

深度学习是人工智能的重要组成部分,随着人工智能的发展受到世人的瞩目^[9]。目前主流的基于深度学习的目标检测算法可分为两大类:以 Faster R-CNN^[10]为代表的 two-stage^[11]检测算法和以 YOLO(You Only Look Once, YOLO)^[12]、SSD^[13]为代表的 one-stage^[14]检测算法。前者是基于候选区域的目标检测算法,这类方法由于需要通过滑动窗口来产生预选窗口,计算量比较大,且无法达到实时的目标检测。后者是基于回归方法的目标检测算法,这类方法使用了回归的思想来确定图像中目标边框以及类别,大大提高了目标检测速度。其中 SSD 结合了 YOLO 中的回归思想和 Faster R-CNN 中的 anchor 机制,使用全图各个位置的多尺度区域特征进行回归,既保持了 YOLO 速度快的特性,也保证了窗口预测跟 Faster R-CNN 一样比较精准。由于基于深度学习的目标检测表现出了较好的效果,越来越多的算法网络被引入遥感领域以实现地面目标的精确快速检测。Zhang 等^[15]使用两个卷积神经网络进行弱监督分类,实现了飞机的检测。Tang 等^[16]使用卷积神经网络获取图片的特征,通过小波压缩方法挑选候选图片块,极限学习机为分类器,实现舰船的检测^[16]。李淑敏等^[17]构建多尺度飞机样本数据集,并将基于深度学习的 YOLO V2 目标检测模型应用于高分辨率遥感图像飞机检测,其检测正确率高达 94.93%;黄金等^[18]将基于深度学习的 SSD 模型应用于高分辨率遥感图像汽车和飞机目标检测,其平均准确率为 81.9%,成功验证了深度学习在汽车和飞机这两类目标检测可行性;方梦梁等^[19]引入基于深度学习的 Faster R-CNN 算法实现光学遥感图像中海面船舶目标检测。唐聪等^[20]在原始 SSD 模型的基础上增加多视窗处理模块,有效提高了 SSD 模型对飞机、鸟类等小目标的检测精度。朱敏超等^[21]在 SSD 模型的基础上去除数据增强部分的随机裁剪操作,提高了模型对遥感图像中小目标的检测精度。以上研究证明:基于深度学习的目标检测可以对遥感图像表现出良好的识别效果。


尾矿库与飞机、汽车、船舶等目标相比,目标尺

度大小不一,缺少统一的形状,周围背景复杂多样,尾砂呈现颜色多样,导致传统的遥感识别方法难以适应大范围内尾矿库目标的高精度自动提取。本文利用深度学习目标检测 SSD 方法对尾矿库进行识别。针对传统监测方法无法做到对尾矿库进行大范围、高频次监测的问题,从尾矿库尺度方面出发,分析尾矿库在遥感图像的特征,同时对模型在不同分辨遥感图像上的适用性进行验证,并对网络进行优化调整,以实现京津冀区域尾矿库高精度自动检测。

2 研究区和数据

2.1 研究区概况

选择京津冀为研究区,如图 1 所示。京津冀区域位于华北地区,包括北京市、天津市和河北省全境,地理范围为 36°05′~42°37′N,113°11′~119°45′E,面积约 21.6 万 km²。京津冀矿产资源丰富,截至 2013 年底,共探明矿种 151 种,查明资源储量的 120 种。矿产种类齐全,铁矿金矿、煤矿以及化工、建材等诸多资源均有分布,其中铁矿占全国总量的 14.31%,主要分布在河北境内,储量占到区域整体的 97%。区域内富矿少、贫矿多,金属矿山以中小型私营矿为主,国有大中型矿山企业较少^[22]。研究区内尾矿库数量占全国尾矿库总量的 25%,且分布杂乱无章难以治理^[23],迫切需要实现京津冀尾矿库高频次、高精度、自动化的监测和管理。



审图号:GS(2019)1822

图 1 京津冀地区

Fig.1 Beijing-Tianjin-Hebei region

2.2 数据源

本研究使用的数据为Google Earth 15级、16级、17级遥感图像,分辨率分别为4 m、2 m和1 m。Google Earth遥感影像将卫星影像和航拍影像融合后呈现在一个三维地球模型上,利用鼠标拉伸即可看到多尺度下的遥感影像。其遥感卫星影像资源主要来自EarthSat的Landsat 7卫星图像、美国DigitalGlobe公司的高分辨率影像、美国Space Imagine公司的IKONOS数据和美国GeoEye-1影像;遥感航拍影像包括Sanborn公司的GIS与地理数据和BlueSky的航拍影像^[24]。从数据源可以看出,Google earth涵盖了全球大部分区域多尺度下的遥感影像。

3 研究方法

研究路线如图2所示。首先分析尾矿库在遥感图像上的特征建立解译标志;第二步,对图像切片,根据解译标志制作样本并将制作好的样本按比例随机分配得到训练集和测试集;第三步,分析模型对分辨率遥感图像的适应性;第四步,对SSD模型网络参数调整优化;第五步,评价模型精度并对京津冀地区尾矿库检测。

3.1 样本库构建与数据准备

通过对尾矿库的形状、结构、尺寸等特征的分

析,结合尾矿库解译标志标记尾矿库的训练样本。考虑到模型训练过程中硬件的运算能力,将遥感图像裁剪成 $1\,500\times 1\,500$ 个像元大小的影像切片,在影像切片上标记尾矿库的外接矩形,最终通过标记、筛选、修正反复迭代后获得尾矿库训练样本9 875张,测试样本500张。将承德市区域的3种分辨率的谷歌图像裁剪成相同像素大小的图像切片,用于模型对不同图像分辨率的适应性分析,最终得到1 m分辨率图像切片42 016张;2 m分辨率图像切片10 504张;4 m分辨率图像切片2 526张。京津冀地区切片图像共计50 257张,用于尾矿库检测。

3.2 网络优化调整

SSD模型训练需要海量样本数据,使用少量训练样本进行网络初始化会导致网络严重过拟合^[25]。遥感图像和自然图像中的低级和中级特征是相似的,可以使用预训练模型来提取样本中的低级特征,只需要样本训练网络后半部分的参数用来提取高级语义信息,这样既提高了训练精度也缩短了训练所需的时间。训练网络模型的软件框架为Caffe,硬件环境为4个12G显存的NVIDIA Titan XP GPU、CUDA2.0以及Intel Xeon E5 CPU,训练10万次需要24小时,将充分训练后的模型用于京津冀地区尾矿库的检测。网络训练时,首先匹配预设框和目标真值框,对于每一个真值框,通过重叠度是否大于0.2来判断预设方框是否与其匹配。那些没有匹配的预设方框,依照得到的置信度损失排序,从大到小选择未匹配的方框,直到其与已匹配方框的数量之比为3:1。迭代训练时通过反向传播不断更新SSD模型中的参数。

原始SSD模型中最大感受野大小只有740个像元,即卷积层输出的特征图单个像元对应的原始输入图像大小为 740×740 。分析发现尾矿库大小在50 m至3 000 m之间,占用的像元个数为25个至1 500个之间;为了使模型预测不同的形状、尺寸的图像时拥有更强的鲁棒性,训练样本图像在输入后会被随机地切割成包含目标对象的小图像块,并且重采样成 $1\,500\times 1\,500$ 像元大小的图像,导致训练样本中有大量的大尺度目标,超出了原始SSD模型的最大感受野范围,无法完全覆盖所有尺寸的尾矿库目标,导致大型尾矿库提取精度差,进而影响整体目标提取精度。

运用文献[26]中的方法增加额外的卷积层以及修改原始SSD网络中卷积步长为2的策略增大

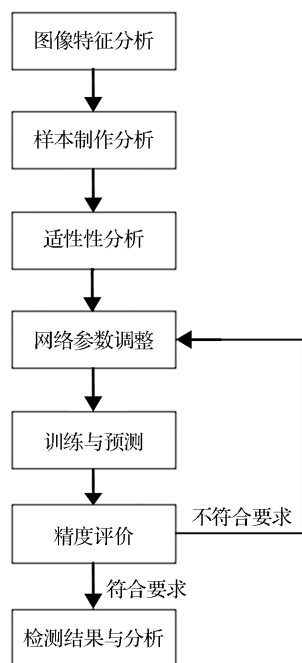


图2 京津冀区域尾矿库提取流程图

Fig.2 Flow chart of tailings pond extraction in Beijing-Tianjin-Hebei region

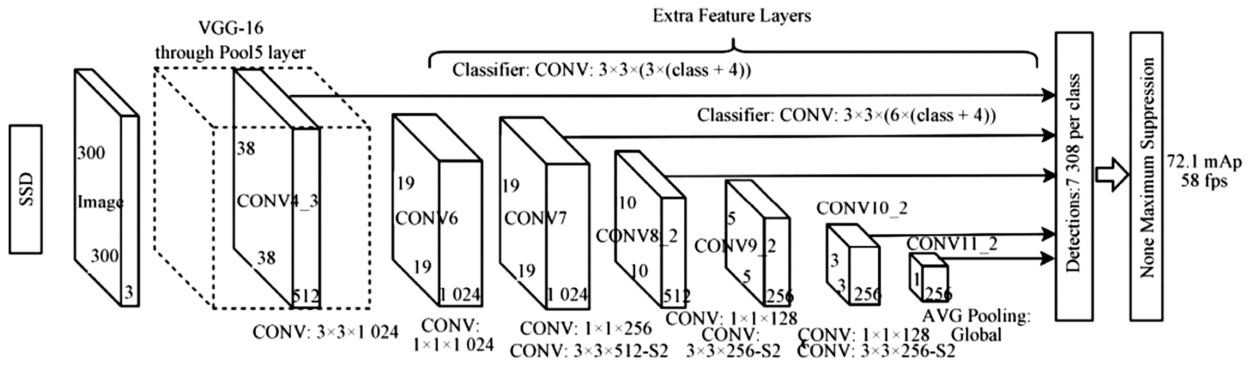


图3 SSD模型结构图

Fig.3 SSD model structure

特征图的感受野。通过修改模型结构将原始SSD模型最大感受野740个像素提升到2499个像素,此外每一层卷积层的特征图感受野都得到一定程度的增大,提高卷积层对大型尾矿库完整特征的捕获能力,以此优化SSD模型对尾矿库这类地物的提取精度^[26]。同时,在合理的范围内对训练参数进行调整,增大批处理参数batch_size可以提高内存利用率,提高大矩阵乘法的并行化效率。考虑到输入影像的尺寸和GPU的显存大小,将batch size设为4;基础学习率base_lr设为0.0001,最大迭代次数max_iter为100K, gamma系数、动量(momentum)和权重衰减参数(weight_decay)分别设为0.1、0.9和0.0005,学习率(learning rate)随着迭代次数而变化,当迭代次数低于20K时,学习率为基础学习率0.0001;当迭代次数大于20K小于30K时,学习率变为0.00001;当迭代次数高于30K时,学习率设为0.000001。

3.3 精度评价

模型的检测性能使用精确率(Precision)、召回率(Recall)和F1分数来评价。精度和召回率的定义如下:

$$\text{精确率: Precision} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{召回率: Recall} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{F1分数: F1} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{recall}}} \quad (3)$$

其中:TP表示实质为尾矿库,被正确检测出来;FP表示实质不是尾矿库,被错误检测出来;FN表示实质为尾矿库,被错误判断为不是尾矿库,没有检测出来;F1分数是综合考虑精度和召回率的性能指标。对于不同的置信度阈值,精度、召回率以及F1分数会不同,以0.1的步长逐步增加置信度阈值

(0.1~0.6),记录模型在不同置信度阈值下的检测性能。

4 结果与分析

4.1 图像特征分析

由于地形、地貌、矿种、采选矿工艺、规模和生产状况等诸多因素的影响,导致了尾矿库类型的多样化。根据尾矿库形态的不同可以将尾矿库大致分为四大类:山谷型、傍山型、平地型、截河型^[23]。山谷型尾矿库如图4(a)所示,是指在山谷谷口处筑坝而形成的尾矿库,该类尾矿库初期坝体相对较短而库区纵深较宽^[23],一般由坝体、尾砂、废水三部分组成,坝体位于山谷口一侧,另外几面都与山谷相接;尾砂在水中密度随着远离坝体而逐渐变得稀释,呈放射状,越接近废水区域尾砂越稀少,在遥感图像上接近正常水体的色调;山谷型尾矿库是最标准、最易辨识的一种类型,也是我国尾矿库中分布




图4 4种类型的尾矿库

Fig.4 Four types of tailings pond

最多、最广泛的一类。

傍山型尾矿库如图4(b)所示,是指在山脚下依靠着山体,在其3面或多面修筑坝体包裹而成尾矿库,该类尾矿库初期坝体相对较长且库区纵深较窄,我国山地丘陵地区的小型尾矿库多为傍山型尾矿库^[23];傍山型尾矿库和山谷型尾矿库结构很相似,也是由坝体、尾砂、废水3部分组成,但是坝体通常是3面包围状态,从遥感图像上可以很清楚地看到由3面坝体包围而成;尾砂及废水的分布与山谷型尾矿库基本一致。

平地型尾矿库如图4(c)所示,是指在平原地区四周筑坝而形成的尾矿库^[23];该类尾矿库初期坝体和后期坝体维护所需工程量大、尾矿库坝体高度较山谷型尾矿库坝体低,我国平坦地带的尾矿库多采用平地型;从图中可以看出平地型尾矿库由坝体和

尾砂组成,一般为干法堆存;由于平地型尾矿库处于平原或沙漠这类平整的区域,坝体需要多个面将库区包围在其中,尾砂色调较为一致。

截河型尾矿库如图4(d)所示,是指在河床上、下游区域分别筑坝形成的尾矿库^[23],该类尾矿库的库面多呈不规则的长方形,尾砂色调与平地型尾矿库较为相似;截河型尾矿库在我国分布较少。

尾矿库样本库中的尾矿库除了类型上的差异以外,在形状、色调、背景及尺度等方面也存在差异,具体情况如图5(a)~(d)所示。

对尾矿库样本矩形标记框高度和宽度、周长、面积进行统计分析,统计情况如图6所示,可以看出矩形标记框高度和宽度为50~3 000 m,主要集中在50~1 400 m之间;周长为300~12 600 m,主要集中在300~2 600 m之间;面积为8 700~9 430 000 m²,




图5 尾矿库多样性

Fig.5 Diversity of tailings pond




Fig.6 Statistics map of tailings pond

主要集中在 8 700~308 700 m²之间;矩形标记框的宽高比、周长、面积反映尾矿库在尺度方面的多样性,为网络参数的调整提供依据。

4.2 空间分辨率的适用性

选择承德市 3 种不同分辨率的图像对模型的适用性进行了验证,分别是谷歌影像 17 级、16 级和 15 级图像,分别对应的空间分辨率是 1 m、2 m 和 4 m。同一尾矿库在这 3 种分辨率遥感图像上的情况如图 7 所示。对这 3 种分辨率的图像进行预测,预测情况如表 1 所示。




图 7 不同空间分辨率遥感图像上的尾矿库
Fig.7 Tailings pond on remote sensing images with difference spatial resolutions

表 1 不同空间分辨率图像下的预测精确度
Table1 Accuracy under different spatial resolution images

空间分辨率	精确度
1 米	0.54
2 米	0.81
4 米	0.73

从表 1 可以看出:尾矿库在不同空间分辨率上的形态差异很小,在检测结果上却不同。不同分辨率影像,尾矿库的监测精度不同。1 m 分辨率下的检测精度为 0.543 相对其他两种分辨率的检测精度低;2 m 分辨率下的检测精度最高为 0.812;4 m 分辨率下的检测精度次之为 0.733。1 m 分辨率影像检测精度较差,可以从以下 3 个方面分析。一是语义信息缺失,二是目标特征不完整,三是 GPU 显存限制。1 m 分辨率的影像确实能使尾矿库的细节纹理信息更加清晰,但是尾矿库尺度一般较大,实际长宽能达到 1~3 km,在 1 m 分辨率影像下能占 1 000~3 000 个像素,由于 Titan Xp 显卡只能吃下 1 536×1 536 尺寸的影像,在这种情况下尾矿库的背景区域会变少,导致语义信息不丰富,会降低检测精度,另外,对于大型尾矿库,一张影像无法涵盖整个目标,造成目标特征丢失,也会降低检测精度。所以用 2 m 分辨率的影像能较好地解决这个问题,

虽然目标纹理会模糊一点,但是能保证目标的整体特征和丰富的语义信息。因此,2 m 空间分辨率影像最适于尾矿库的检测。

4.3 提取结果和精度

网络模型训练过程中,当迭代次数到达 10 万次时停止网络训练,训练的损失曲线和准确率曲线如图 8 所示。在训练 10 万次后 loss 曲线值下降到了 1.4,并趋于稳定,说明网络达到了很好的收敛,同时网络的准确率达到 84.5%。




图 8 网络训练结果
Fig.8 Network training results

置信度阈值对尾矿库监测精度有很大的影响,本文通过一系列不同置信度阈值(0.1~0.6)设置的检测结果的精度评价,综合权衡 F1 分数、精确率和召回率,确定最优的置信度设置。不同阈值下的精度、召回率和 F1 分数如表 2 所示。从统计结果表中

可以看到,置信度在 0.1~0.6 范围内,随着置信度阈值的增加,误检尾矿库数量逐渐减少,漏检尾矿库数量逐渐增加,从而导致精确度随着阈值的增加而提高,召回率随着阈值的增加而减弱,其中精确率

最高为 97.5%,召回率最高为 98.8%。置信度阈值为 0.3 时,F1 分数最高,即置信度阈值设置为 0.3 时模型的性能最好。因此,将置信度阈值设置为 0.3 对京津冀区域尾矿库进行检测。

表 2 预测结果统计表
Table2 Forecast result statistics

置信度阈值	真实个数	预测个数	正检个数 TP	误检个数 FP	漏检个数 FN	精确率	召回率	F1 分数
0.1	911	1 753	900	853	11	0.51	0.99	0.68
0.2		1 054	865	189	46	0.82	0.95	0.88
0.3		896	808	88	103	0.90	0.89	0.89
0.4		810	759	51	152	0.94	0.83	0.88
0.5		738	709	29	202	0.96	0.83	0.89
0.6		686	669	17	242	0.98	0.73	0.84

利用 2 个 GPU1 小时内完成京津冀区域的尾矿库检测,检测出尾矿库 2 696,尾矿库分布如图 9 所示。从图 9 可以看出,该区域尾矿库主要集中分

布在张家口市、承德市、唐山市境内,保定市和石家庄市零散分布,北京市内也有少量尾矿库存在。

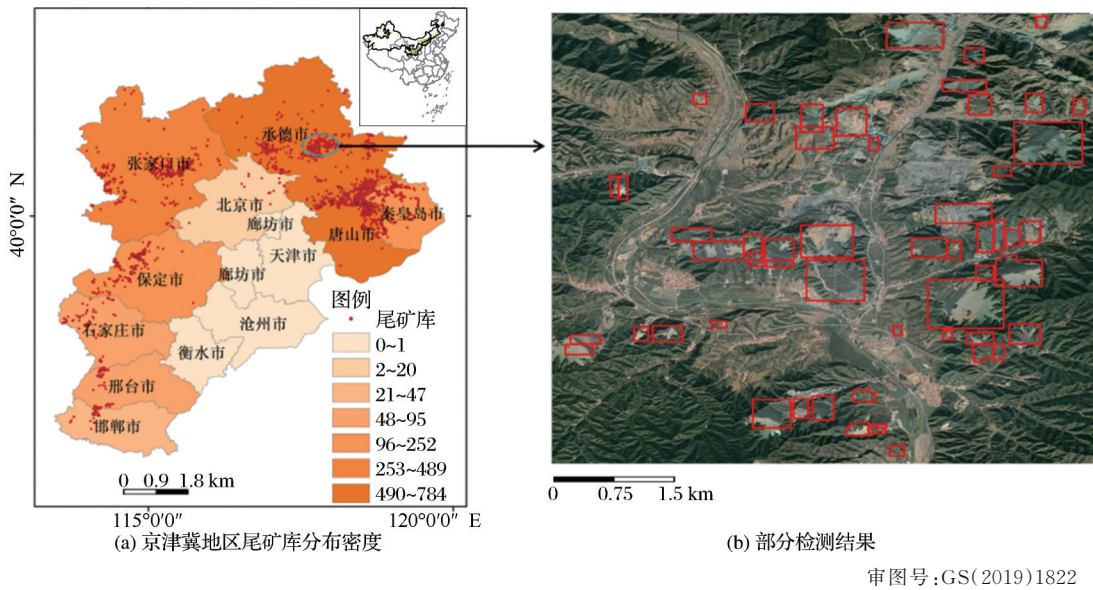


图 9 检测结果
Fig.9 Test results

5 讨 论

针对传统监测方法无法做到对尾矿库进行大范围、高频次监测的问题,提出了基于深度学习目标检测的方法对尾矿库进行自动快速识别,取得了较好的效果。该方法与传统的尾矿库检测方法相比具有很大的优势。第一,深度学习方法可以自动的提取尾矿库的特征,不需要人工设计,检测速度更快,同时也消除了人为主观性的影响,提取结果更准确;第二,在不同分辨率的遥感图像上对模型的适用性进行了测试;第三,本文根据尾矿库在遥

感图像上的特点对原始 SSD 网络进行了调整,提高了模型的检测精度。

不同空间分辨率图像的检测结果如图 10 所示。从不同空间分辨率下的尾矿库检测情况可以看出,当模型预测 2 m 和 4 m 分辨率图像上的尾矿库时都取得了较好的检测结果,特别是在检测较大面积的尾矿库时,4 m 分辨率图像上的检测结果要优于 2 m 分辨率图像上的检测结果,但在面积较小的尾矿库的检测性能上则较差;当分辨率为 2 m 时,它可以检测到面积大小不同的各种尾矿库,总体检测性能较

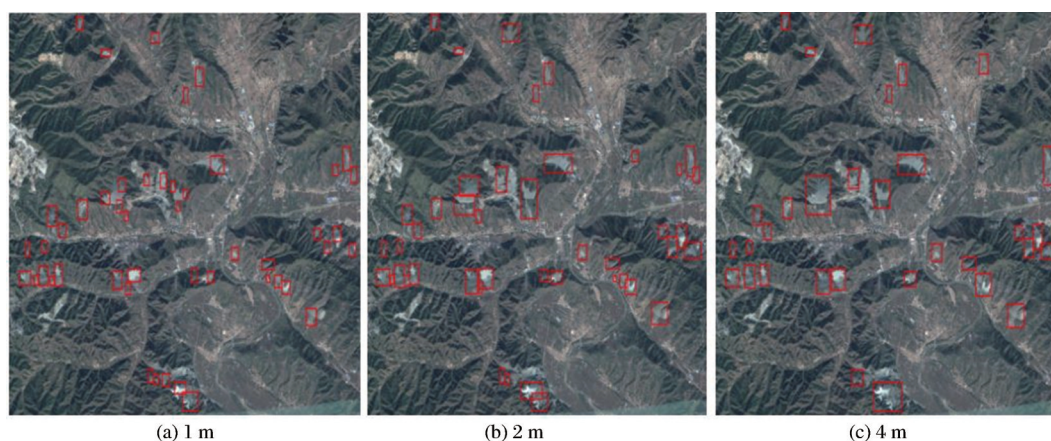


图10 不同分辨率图像上的检测结果

Fig.10 Detection results on images of different resolutions

好;当分辨率为1 m时,由于预设框的尺寸比图像上尾矿库的尺寸小得多,许多大型尾矿库不能被检测到或仅能检测到尾矿库的局部,导致大量误检,使得检测结果精度较差。为此选择2 m的空间分辨率图像作为最终检测用的图像。

针对尾矿库在结构、尺寸、纹理、色调等方面的差异,构建了一个多尺度、多类型的尾矿库样本库,在数据层面提高了模型检测尾矿库的鲁棒性。由于深度学习模型训练需要海量了样本数据,针对样本数量相对较少的问题,本文基于遥感图像和自然图像中的低级和中级特征是相似的特点,使用预训练模型提取样本中的低级特征,采用样本训练网络后半部分参数提取高级语义信息,有效避免模型的过拟合问题,又能提高模型的检测性能。

在样本制作过程中,考虑到是将尾矿库的整体特征作检测对象进行样本标记,致使尾矿库外接矩形框中包含了其他地物信息,并且尾矿库一般由坝体、尾砂和废水组成,这些组成部分的纹理、色调与裸地、水体等地物十分相似,加之尾矿库本身存在形状、尾砂色调、背景、类型、尺度大小等多多样性,导致了模型在检测过程中将植被、裸地、水体、雪和云等错误检测成尾矿库。模型部分误检情况如图11所示。

后续研究将深入分析误检的原因,基于不同分辨率的图像训练适应于不同分辨率的模型,针对尾矿库的形态和尺度特点确定、最优空间分辨率、模型和检测策略,从而提高模型的精度和泛化能力。

6 结 论

本文针对尾矿库高频次高分辨率提取的要求,基于深度学习目标检测方法实现了尾矿库的自动



图11 模型误检地物

Fig.11 Some objects of mis-detected

快速识别,结合尾矿库自身的特点,改进和调整了网络模型。结果表明,模型的检测精度达到了90.2%,召回率达到了88.7%,证明了深度学习目标检测方法对于遥感图像上复杂地物的检测是有效的。在后续的研究中,将进一步研究此方法在全国及全球范围内检测尾矿库的有效性,并探索模型对于其他多源遥感数据的适用性。

参考文献(References):

- [1] Wang Tao, Hou Kepeng, Guo Zhenshi, *et al.* Application of Analytic Hierarchy Process to Tailings Pond Safety Operation Analysis[J]. Rock and Soil Mechanics, 2008, 29(Sup.1): 680-687. [王涛, 侯克鹏, 郭振世, 张成良. 层次分析法(AHP)在尾矿库安全运行分析中的应用[J]. 岩土力学, 2008, 29(增刊1): 680-686.]
- [2] Tian Wenqi, Xie Xuyang. Tailings Pond Situation in China and Safety Countermeasure Suggestion[J]. China Mine Engineering, 2009, 38(6): 42-49. [田文旗, 谢旭阳. 我国尾矿库现状及安全对策的建议[J]. 中国矿山工程, 2009, 38(6): 42-49.]
- [3] Tan Qulin, Shao Yun. Application of Remote Sensing Technology to Environment Pollution Monitoring[J]. Remote Sensing Technology and Application, 2000, 15(4): 246-251. [谭衢霖, 邵芸. 遥感技术在环境污染监测中的应用[J]. 遥感技术与应用, 2000, 15(4): 246-251.]
- [4] Hao Lina, Zhang Zhi, He Wenxi, *et al.* Tailings Reservoir Rec-

- ognition Factors of the High Resolution Remote Sensing Image in Southeastern Hubei[J]. Remote Sensing for Land and Resources, 2012, 24(3): 154-158. [郝利娜, 张志, 何文熹, 等. 鄂东南尾矿库高分辨率遥感图像识别因子研究[J]. 国土资源遥感, 2012, 24(3): 154-158.]
- [5] Qiang Jianhua. Remote Sensing Investigation and Environment Impact Analysis of Tailing Dams in Shaanxi Province[J]. Metal Mine, 2013, 42(10): 112-115. [强建华. 陕西省尾矿库遥感调查与环境影响分析[J]. 金属矿山, 2013, 42(10): 112-115.]
- [6] Xiao Rulin, Lv Jie, Fu Zhuo, *et al.* The Application Remote Sensing in the Environment Risk Monitoring of Tailings Pond in Zhangjiakou City, China[J]. Remote Sensing Technology and Application, 2014, 29(1): 100-105. [肖如林, 吕杰, 付卓, 等. 张家口市尾矿库环境风险遥感监测应用研究[J]. 遥感技术与应用, 2014, 29(1): 100-105.]
- [7] Wang Chuangye, Du Xiaoya, Cai Zonglei. Extraction and Interpretation on Remote Sensing Information of Tailings and Solid Waster[J]. Coal Technology, 2017, 36(7): 17-19. [王创业, 杜晓娅, 蔡宗磊. 尾矿及固体废弃物遥感信息提取与解译[J]. 煤炭技术, 2017, 36(7): 17-19.]
- [8] Zhou Yingjie, Wang Xiaohong, Yao Weiling, *et al.* Remote Sensing Investigation and Environment Impact Analysis of Tailing Ponds in Shandong Province[J]. Geological Survey of China, 2017, 4(4): 88-92. [周英杰, 王晓红, 姚维岭, 等. 山东省尾矿库遥感调查与环境影响分析[J]. 中国地质调查, 2017, 4(4): 88-92.]
- [9] Hinton GE, Osindero S, Teh YW. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [10] Ren S, He K, Girshick R. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [11] Chai Zifeng. Method About Sliding-Windows-based Weakly Labeled Object Detection[D]. Harbin: Harbin Institute of Technology, 2016. [柴子峰. 基于滑动窗口的弱标记物体检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.]
- [12] Joseph R, Santosh D, Ross G, *et al.* You Only Look Once: Unified, Real-time Object Detection[J]. CVPR 2016. doi: 10.1109/CVPR.2016.91.
- [13] Liu W, Anguelov D, Erhan D, *et al.* SSD: Single Shot Multi-box Detector[C]// European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [14] Girshick R. Fast R-CNN[C]// The IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [15] Zhang F, Du B, Zhang L, *et al.* Weakly Supervised Searning based on Coupled Convolutional Neural Networks for Aircraft Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(9): 5553-5563. doi: 10.1109/TGRS. 2016. 2569141.
- [16] Tang J, Deng C, Huang G, *et al.* Compressed-domain Ship Detection on Spaceborne Optical Image Using Deep Neural Network and Extreme Learning Machine[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1174-1185. doi: 10.1109/TGRS.2014.2335751.
- [17] Li Shumin, Feng Quanlong, Liang Qichun, *et al.* Aircraft in Domestic High Resolution Remote Sensing Images Using Deep-learning[J]. Remote Sensing Technology and Application, 2018, 33(6): 1095-1102. [李淑敏, 冯权泷, 梁其椿, 等. 基于深度学习的国产高分遥感影像飞机目标自动检测[J]. 遥感技术与应用, 2018, 33(6): 1095-1102.]
- [18] Huang Jin, Fu Fa, Zhao Na. Research on the Application of Deep Learning in Remote Sensing Images Objection Detection[J]. Wireless Internet Technology, 2019, 16(1): 11-13. [黄金, 付发, 赵娜. 深度学习在遥感图像目标检测中的应用研究[J]. 无线互联科技, 2019, 16(1): 11-13.]
- [19] Fang Mengliang, Huang Gang. A Ship Detection Method in Optical Remote Sensing Images[J]. Computer Technology and Development, 2019(8): 1-6. [方梦梁, 黄刚. 一种光学遥感图像船舶目标检测技术[J]. 计算机技术与发展, 2019(8): 1-6.]
- [20] Tang Cong, Ling Yongshun, Zheng Kedong, *et al.* Object Detection Method of Multi-View SSD based on Deep Learning[J]. Infrared and Laser Engineering, 2018, 47(1): 302-310. [唐聪, 凌永顺, 郑科栋, 等. 基于深度学习的多视窗SSD目标检测方法[J]. 红外与激光工程, 2018, 47(1): 302-310.]
- [21] Zhu Minchao, Feng Tao, Zhang Yu. Remote Sensing Image Multi-target Detection Method based on FD-SSD[J]. Computer Applications and Software, 2019, 36(1): 232-238. [朱敏超, 冯涛, 张钰. 基于FD-SSD的遥感图像多目标检测方法[J]. 计算机应用与软件, 2019, 36(1): 232-238.]
- [22] Ge Rongfeng, Xu Kaipeng, Chi Yanyan, *et al.* Eco-environmental Impact of Mineral Resources Exploitation in Beijing-Tianjin-Hebei Region[J]. Chinese Journal of Environmental Management, 2017, 9(3): 46-51. [葛荣凤, 许开鹏, 迟妍妍, 等. 京津冀地区矿产资源开发的生态环境影响研究[J]. 中国资源管理, 2017, 9(3): 46-51.]
- [23] Lv Jie. Remote Sensing Research and Application of Tailings Pond—A Case Study of Tailings Pond in Hebei Province[D]. Beijing: China University of Geosciences, 2014. [吕杰. 尾矿库遥感监测技术研究与应用—以河北省尾矿库为例[D]. 北京: 中国地质大学, 2014.]
- [24] Zhang Shifu. Discussion on the Method of High-resolution Images Acquisition based on Google Earth[J]. Electronic Technology, 2013(12): 16-18. [张世富. 基于Google Earth的高分辨率影像获取方法探讨[J]. 电子技术, 2013(12): 16-18.]
- [25] Lu Kaixuan, Li Guoqing, Chen Zhengchao, *et al.* Extraction of Steel Plants Based on Optimized SSD Network Incorporating Negative Sample's Multi Channels[J]. Journal of University of Chinese Academy of Sciences, 2020, 37(3): 352-359. [卢凯旋, 李国清, 陈正超, 等. 基于负样本多通道优化SSD网络的钢铁厂提取[J]. 中国科学院大学学报, 2020, 37(3): 352-359.]

- [26] Yan Kai, Shen Ting, Chen Zhengchao, *et al.* Automatic Extraction of Tailing Pond based on SSD of Deep Learning[J]. Journal of University of Chinese Academy of Sciences, 2020, 37

(3):360-367.[闫凯,沈汀,陈正超,等.基于深度学习的 SSD 模型尾矿库自动提取[J].中国科学院大学学报,2020,37(3):360-367.]

Detection of Tailings Pond in Beijing—Tianjin—Hebei Region based on SSD Model

Li Qing^{1,2}, Chen Junjie¹, Li Qingting², Li Baipeng², Lu Kaixuan²,
Zan Luyang², Chen Zhengchao²

(1.School of Surveying and Land Information Engineering, Henan Polytechnic University,
Jiaozuo 454000, China;

2.Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China)

Abstract: The accidents of the tailing ponds in China are frequent, the damage caused by dam breaking is extremely serious. The current quantity and distribution of tailings pond is necessary for preventing tailings pond accidents and carrying out emergency work in tailings pond. The traditional survey method is mainly based on ground investigations, which is difficult to achieve large-scale high-frequency monitoring. A tailing pond detection method based on deep learning detection was proposed in this paper, which can quickly identify the locations of the tailing ponds and obtain their geographical distribution. The suitable training samples are produced based on the study of the characteristics of the tailing ponds on the remote sensing image. SSD (Single Shot Multibox Detector) model is adjusted according to the samples characteristics during the model training. The extraction of the tailing ponds in the Beijing-Tianjin-Hebei Region is realized based on optimized model. The experiment result shows that there are 2 696 tailing ponds which were detected in the Beijing-Tianjin-Hebei Region, the recall reaches 93.3%. This paper realized the extract the tailings pond with the method of deep learning target detection, and has achieve good results which can provides method for the national and global extraction of tailing ponds.

Key words: Remote sensing; Deep learning; Target detection; Tailings pond; Beijing-Tianjin-Hebei