

doi: 10.6046/zrzyg.2023147

引用格式: 郭勇, 张琳翔, 许泽宇, 等. 结合桥梁难分样本优化的大清河流域水坝遥感检测[J]. 自然资源遥感, 2024, 36(4): 201-209. (Guo Y, Zhang L X, Xu Z Y, et al. Remote sensing-based detection of dams in the Daqing River basin through optimization using hard negative samples of bridges[J]. Remote Sensing for Natural Resources, 2024, 36(4): 201-209.)

结合桥梁难分样本优化的大清河流域水坝遥感检测

郭勇¹, 张琳翔¹, 许泽宇², 蔡中祥¹

(1. 信息工程大学地理空间信息学院, 郑州 450052; 2. 中国科学院空天信息
创新研究院国家遥感应用工程技术研究中心, 北京 100101)

摘要: 水坝的检测对于城市规划、生态环境评估等有着重要意义。目前基于遥感的水坝检测研究主要是基于样本集的算法改进或在小区域上的检测, 缺乏在大尺度地学区域的实践应用。而在大区域中, 水坝分布稀疏, 地表存在更多的桥梁等地物会对水坝的检测形成显著干扰。为应对这一问题, 该文以大清河流域为例, 研究大尺度区域内的水坝遥感检测。该文研究主要分为2个阶段, 第一阶段是将容易与水坝混淆的桥梁作为难分负样本(即容易产生假阳性的样本)参加训练, 基于DIOR公开数据集改进适合于水坝提取的神经网络结构; 第二阶段是基于优化后的网络以及大区域多源样本数据进行微调训练获取模型, 并实现大清河区域的水坝检测。优化后的模型在第一阶段测试中水坝检测F1分数为0.783, 在第二阶段大清河流域检测得到了330处水坝, 其结果与现有公开的水坝空间分布数据集GRandD相符, 且更为详细。结果表明, 结合桥梁样本优化训练后的模型可以有效避免对桥梁的误提取, 从而提高检测精度。

关键词: 水坝; 难分负样本; 大清河流域; CenterNet网络; 目标检测

中图法分类号: TP 751 **文献标志码:** A **文章编号:** 2097-034X(2024)04-0201-09

0 引言

水坝可以对自然界的水进行控制、调节、开发、利用和保护, 以减轻和免除水旱灾害, 并利用水资源, 适应人类社会和自然环境的需要^[1]。对水坝目标的识别和检测可以为水坝的管理和规划等提供重要信息。而结合遥感数据检测范围大、采集速度快等特点, 可以实现对水坝的快速识别和检测^[2]。高空间分辨率遥感影像也已成为地表目标检测的重要数据源^[3]。

传统的目标检测方法对于水坝的检测精度和自动化程度都较低^[1]。如朱然^[2]通过阈值分割水域目标、几何特性定位等方法, 基于航拍影像实现了对桥梁水坝轮廓的检测; 邱丹丹等^[4]结合多源卫星影像以及特征级融合的模式, 提取得到水坝目标。这些方法的特征提取能力有限, 难以达到很高的精度。近些年来, 深度学习技术快速发展, 在目标检测领域也达到了很高的精度^[5-8]。目前, 深度学习方法被广泛应用于飞机^[9-11]、舰船^[11-13]、车辆^[14-15]、房

屋建筑^[16-17]等地物的提取中, 但对于水坝检测的研究较少。现有研究中, Jing等^[18]基于YOLO网络结构, 利用谷歌影像成功检测到了112座水坝, 并找到了39个未知水坝。该研究通过开放街道地图(OpenStreetMap, OSM)等在线数据约束桥梁等背景干扰信息。然而, OSM等数据在不同地理区域精细度和准确度不同, 因此提取结果精度也不易控制。许泽宇等^[19]基于改进的YOLO网络和高分二号影像数据研究了大面幅遥感影像中水利设施的提取, 但其使用的近红外波段数据在一些实际应用中不易获取, 且没有开展对完整地学区域(如流域)的检测。

部分桥梁和水坝光谱和形状纹理信息以及所处环境非常相似, 且桥梁通常与陆地上的道路直接相连, 部分水坝也与道路相连通, 因此, 对两者的目标检测容易发生混淆, 尤其是在大区域内, 桥梁的数量会远远高于水坝数量, 混淆问题更为明显。本文引入难分样本的思想以优化水坝的提取, 将桥梁样本视为难以分辨的负样本。难分负样本挖掘^[20]是一种常用的解决方法, 在计算机视觉^[21]以及遥感目标检测^[22]等领域均有成功应用。目前应用思路是首

收稿日期: 2023-05-23; 修订日期: 2024-02-13

基金项目: 新疆维吾尔自治区重点研发任务专项“强震次生地质灾害承灾体识别与受损评估研究”(编号: 2022B03001-3)和新疆第三次科学考察项目“新疆遥感动态监测系统及时序信息反演”(编号: 2021xjkk1403)共同资助。

第一作者: 郭勇(1983-), 男, 博士, 讲师, 主要从事目标智能识别研究。Email: gy86322@sina.com。

先通过深度学习训练,选出容易与目标产生混淆的负样本,再对其进行针对性训练,通过多次循环逐渐优化训练模型。而在本文的水坝检测中,桥梁可直接被认为是负样本而不需要初步训练后再确定。难分负样本挖掘通常使用同一神经网络结构,而本文则测试多种网络结构,以探索适合区分水坝和桥梁的神经网络解决方案。

总体上,本文研究分为 2 个阶段:第一阶段是结合桥梁样本的网络结构优化,考虑到水坝检测任务更看重目标中心位置而非检测框的长宽数值^[4,23],以基于中心点回归的 CenterNet^[24]网络为基础,结合 U-Net 等网络的特征融合机制进行优化;第二阶段利用优化好的网络结构和模型,结合大清河流域卫星数据以及其他区域的水坝辅助样本,研究优化完整流域范围下的水坝目标检测。

1 研究区概况与数据源

1.1 研究区概况

研究区域为大清河流域(图 1)。

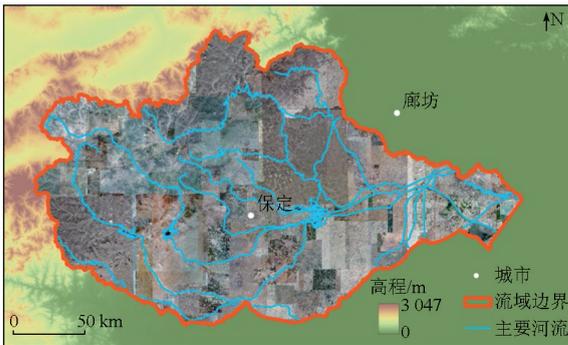


图 1 大清河流域影像及位置

Fig.1 Image and location of the Daqing River basin

大清河是中国海河流域支流之一,发源于山西省任丘市,流经山西、河北、北京、天津 4 省市,流域主体位于河北省保定市,总面积达 43 296 km²^[25]。

1.2 数据源

第一阶段,由于水坝属于稀少地物,在研究区内取样则数据量不足以支撑网络结构的对比研究。因此在第一阶段选用 DIOR 公开数据集^[26]。DIOR 数据集是一个公开的光学遥感目标检测数据集,包含 23 463 幅图像,共有 192 472 个实例,包括飞机、机场、桥梁、水坝等 20 个类别。该数据集的图像分辨率、成像条件、天气、季节等都有变化,因此适合验证深度学习模型的检测能力。本文研究中,只提取该数据集中的桥梁和水坝 2 个类别进行研究。经过提取后,共得到 3 035 景影像,其中 1 311 景为训练集数据,1 724 景为测试集数据。

在第二阶段,以 18 级谷歌影像为基础提取大清河流域的水坝。数据总量达 1.03 TB,影像示意图见图 1 中底图。研究使用大清河流域水坝及桥梁样本各 40 景。由于样本量依然较少,本研究加入课题组在新疆科考中得到的 30 景水坝样本数据,并基于 DIOR 数据的训练模型进行微调。3 种样本数据示意图如图 2 所示。同时,为了评估本文检测结果,使用 2 个公开数据集:第一个是全球水坝数据集(global reservoir and dam database, GRandD)^[27],包含全球 7 320 个水库及相关大坝的数据,该数据集标记了水坝位置等信息;第二个是中科院南京地理所发布的全国水库数据集(China reservoir dataset, CRD)^[28],CRD 数据集共提供全国 97 435 个水库的空间位置信息。



(a) 大清河流域样本

(b) DIOR 数据样本

(c) 新疆水利设施样本

图 2 第二阶段使用的 3 种样本数据示意图

Fig.2 Schematic diagram of the three types of sample data used in the second stage

2 研究方法

2.1 U-CenterNet 网络

2.1.1 CenterNet 网络

卷积神经网络 (convolutional neural network, CNN)^[29] 是一种基础网络结构,可以拓展得到多种网络^[30-31],在图像识别^[30-32]、目标检测^[5,7,8]、语义分割^[31,33]等领域都展现出了很好的效果。CenterNet 网络是一种典型的无锚框 CNN,在 CornerNet 的基础上发展而来。首先根据样本中目标框的大小,结合高斯滤波器生成热度图;再通过特征提取网络及上采样提取热度图,得到物体的中心点,并回归目标的宽度和高度。该方法直接在热度图上进行了过滤操作,去掉了耗时的非极大值抑制 (non-maximum suppression, NMS) 处理过程。然而,在对于桥梁和水坝提取的具体问题中,该网络的部分内容需要进一步考虑,另外 NMS 等算法操作也需要进一步评估。

2.1.2 改进后的 U-CenterNet 网络

本文中,将改进后的 CenterNet 网络命名为 U-

CenterNet 网络。在通过高分辨率遥感影像得到的样本中,桥梁和水坝尺度不统一,部分桥梁和水坝属于较大目标,如图 3 所示,因此使用原始方法通过热度图进行回归时容易出现较大误差。



(a) 桥梁

(b) 水坝

图 3 存在大目标的桥梁和水坝样本数据示意图

Fig.3 Schematic diagram of sample data of bridge and dam with large objects

由于部分桥梁和水坝形态特征相似,因此在网络中,需要保留足够多的细节。改进后的 U-CenterNet 网络结构如图 4 所示。对第三次上采样后得到的特征图,经过卷积得到中心点位置、检测框的宽高信息和目标的类别信息。

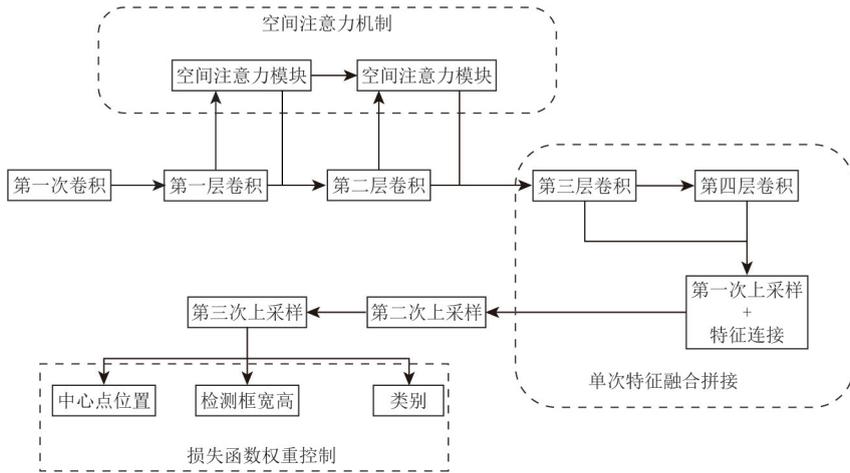


图 4 U-CenterNet 结构示意图

Fig.4 Schematic diagram of U-CenterNet structure

1) 融合空间注意力机制,提升对空间信息特征的提取效果。空间注意力机制首先通过最大池化和均值池化处理,并将结果拼接成特征图,再通过卷积和激活函数处理,过程如图 5 所示。通过空间注意力机制,可以突出空间上的局部信息。由于遥感影像中各种地物空间分布存在多种情况,因此空间注

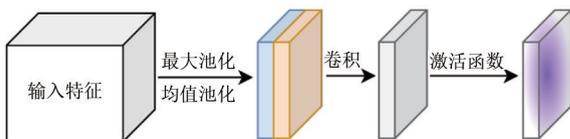


图 5 空间注意力机制示意图

Fig.5 Schematic diagram of spatial attention mechanism

意力机制可以增强对目标特征的提取效果。

2) 结合并调整 U-Net 网络结构,增强编码器-解码器之间的信息连接和融合。在生成热度图时,其结构与语义分割网络类似,因此,融入典型语义分割网络 U-Net 的部分结构,以增强编码器和解码器的连接,优化热度图的获取效果。首先将深层特征进行上采样,再与浅层特征拼接,然后通过卷积得到上采样后的综合特征,如图 6 所示。通过该方法,可以融合浅层特征中的细节信息。与 U-Net 不同之处在于,本文结构中的方法是为了得到热度图而不是语义分割结果,不需要特别详细的形状信息,因此仅在第一次上采样后的特征进行信息连接和融合,

对于更浅层的特征,其包含更多目标形状细节信息干扰,不再进行拼接。

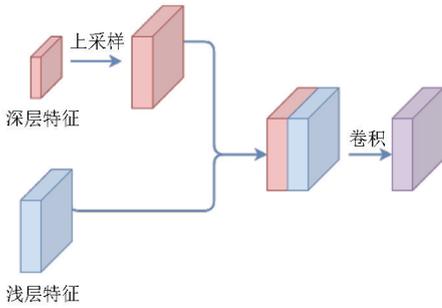


图 6 特征拼接融合过程示意图

Fig.6 Schematic diagram of the feature splicing and fusion process

3) 调整损失函数中宽高损失的权重。在基于遥感数据的桥梁和水坝检测任务中,主要提取目标的类型和位置,其边界框的宽、高形状不是提取的关键任务,因此降低宽高损失权重,本文中,将宽、高损失降低为原方法的 1/10。

2.2 精度评价方案

评价指标采用精确度 (Precision)、召回率 (Recall) 和 F1 分数。精确度即查准率,表示预测的结果中准确预测的目标所占的比例;召回率即查全率,表示真实目标中有多少比例目标被正确检测出来。设 TP 为样本真实数据和模型输出的预测框都为正确的分类目标的数量; FN 为样本真实数据为正确目标,但模型输出没有检测出的数量; FP 为样本真实数据没有正确目标,但该位置模型输出了目标的数量。根据上述的 3 个精度指标,可以得到精确度和召回率,公式为:

$$Precision = \frac{TP}{TP + FP}, \quad (1)$$

$$Recall = \frac{TP}{TP + FN}. \quad (2)$$

在此基础上,得到 F 分数:

$$F = \frac{(1 + \beta^2) \cdot Precision \cdot Recall}{\beta^2 \cdot Precision + Recall}, \quad (3)$$

式中 β 为参数值,可以影响精确度和召回率在综合精度评价时的权重。虽然水坝检测更关注召回率,但本阶段使用了桥梁样本,过多的假阳性桥梁样本会对水坝识别形成干扰,因此本文采用 $\beta = 1$,即采用 F1 精度作为综合精度指标,不侧重单一指标。

3 实验与分析

3.1 实验设置

本文实验环境为 Windows 11 操作系统,

NVIDIA GeForce RTX 3070 GPU 显卡,实现程序为 Python 语言和 PyTorch 深度学习框架。

第一阶段实验设置训练过程为 300 个 epoch,使用 ResNet50 预训练模型,所有的网络结构都使用 Adam 优化器和基于余弦退火的学习率衰减方案。由于本文提出的网络中包含新的结构,因此在新的网络中,只加载与预训练模型中相同结构部分。实验设置对比网络为: Faster R-CNN^[8], YOLO v3^[6], YOLO v7x^[34] 和原始 CenterNet。Faster R-CNN^[8] 和 YOLO^[6] 是 2 种典型且高效的目标检测网络结构。Faster R-CNN 由 R-CNN^[20] 和 Fast R-CNN^[35] 逐渐发展而来,有很高的检测精度。该网络流程主要分为 2 步,第一步找到图片中待检测物体的锚框,第二步对锚框进行分类。Faster R-CNN 已成功应用于建筑、飞机、船舶等遥感地物目标的提取^[36-37]。YOLO 是典型的单阶段检测器,可以一步直接检测到目标。目前 YOLO 的多个版本被应用于遥感地物检测中^[9,10,18],本文对比的是经典的 YOLO v3 和新提出的 v7 增强版本 YOLO v7x。

第二阶段实验使用在 DIOR 数据集中得到的模型,并结合大清河流域的水坝和桥梁样本数据各 40 景,引入 30 景新疆水坝数据作为补充,并结合 GRandD 和 CRD 公开数据集评估结果。

3.2 结果与分析

3.2.1 第一阶段实验结果

第一阶段是基于 DIOR 数据集得到的桥梁水坝检测,图 7 展示了实验过程中损失值 (Loss) 的变化。需要注意的是,由于不同网络结构使用的损失函数不同,每个 epoch 下 Loss 数值的大小不代表模型的精度差异。最终得到的水坝和桥梁的检测精度如表 1 所示。本阶段所用数据直接从 DIOR 数据集中提取而来,其测试样本数大于训练样本数,因此得到的精度值偏低,但也可以表征算法的检测能力。根据

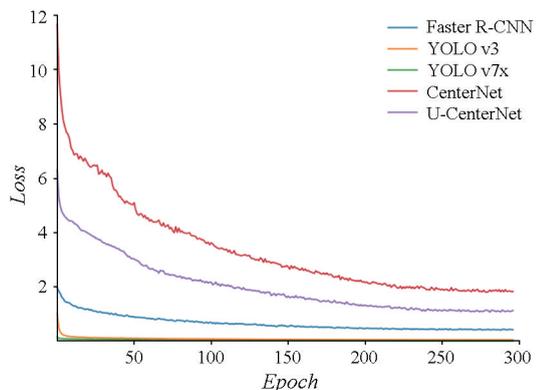


图 7 训练中各模型 Loss 值随 epoch 的变化

Fig.7 Changes in the Loss values of each model during training with epochs

表 1 DIOR 数据集检测精度

Tab.1 Detection accuracy of DIOR dataset

深度学习网络	类别	精确度	召回率	F1 分数
Faster R-CNN	桥梁	0.540	0.646	0.588
	水坝	0.648	0.896	0.752
YOLO v3	桥梁	0.578	0.780	0.664
	水坝	0.627	0.814	0.708
YOLO v7x	桥梁	0.662	0.517	0.541
	水坝	0.702	0.803	0.780
CenterNet	桥梁	0.548	0.797	0.649
	水坝	0.577	0.765	0.658
U-CenterNet	桥梁	0.639	0.775	0.700
	水坝	0.773	0.793	0.783

表 1, U-CenterNet 有最高的水坝检测精度, YOLO v7x 的水坝检测精度略低于 U-CenterNet 接近。原

始 CenterNet 没有使用 NMS 机制, 同一目标的重复预测过多, 因此精确度下降, 其最终的 F1 平均分数也低于 Faster R-CNN, YOLO v3, YOLO v7x 网络。虽然 CenterNet 是根据热度图峰值得到中心点, 进而生成预测框, 从原理上可以降低重叠预测框的问题, 但对于目标较大的地物, 其热度图峰值可能不止一个, 因此可能出现重叠较多的情况。而在加入 NMS 后, 可以得到明显改善; 同时结合 U-Net 结构的特征融合能力, 进一步提高提取精度。YOLO v7x 虽然是比较新的网络, 但其计算资源消耗也更大, 且是基于通用计算机视觉数据集对前代版本所作的优化, 在本文的水坝检测中没有体现出明显优势。为了展示不同网络结构检测结果的细节, 表 2 展示了典型检测结果的示意。

表 2 各网络结构典型检测结果对比示例

Tab.2 Comparison examples of typical detection results of different network structures

网络	示例 1	示例 2	示例 3	示例 4
真实标签				
Faster R-CNN				
YOLO v3				
YOLO v7x				
CenterNet				
U-CenterNet				

在示例 1 中, 对于河流上的水坝, 多数算法结果有重叠及错检现象, 如 YOLO v3 错误地识别出了桥

梁信息。在示例 2 中, 原始 CenterNet 和桥梁和部分陆地地物识别为了水坝, YOLO v3 则将与桥梁连接

的部分道路识别为了水坝,而改进后的 U-CenterNet 网络没有错误识别。在示例 3 中,原始 CenterNet, Faster R-CNN 和 YOLO v7x 将桥梁错误识别为了水坝, YOLO v3 和改进后的 U-CenterNet 网络正确检测到了桥梁,但 YOLO v3 结果出现重复。在示例 4 中,原始 CenterNet 的结果存在重叠,且其中一个重叠框将桥梁识别为水坝。而 U-CenterNet 可以准确识别。整体上看,U-CenterNet 结果中将桥梁误检测为水坝的情况最少,可以明显降低桥梁这一难分地物信息带来的干扰。

3.2.2 第二阶段提取结果

本文研究共得到了水坝点 584 处,经人工快速筛选后得到最终结果 330 处,典型问题如图 8 所示。图 8(a)中存在重复检测的现象;图 8(b)中依然可以看到部分桥梁被识别为了水坝;图 8(c)中部分农田区域的光谱和纹理特征与大坝相似,因此也被识别为了水坝。由于大清河流域存在多种地形结构且地物特征复杂,经过本文的优化方法后依然会产生类似的混淆和误差,但本文提出的方法已经明显提高了完整区域的水坝提取效率。

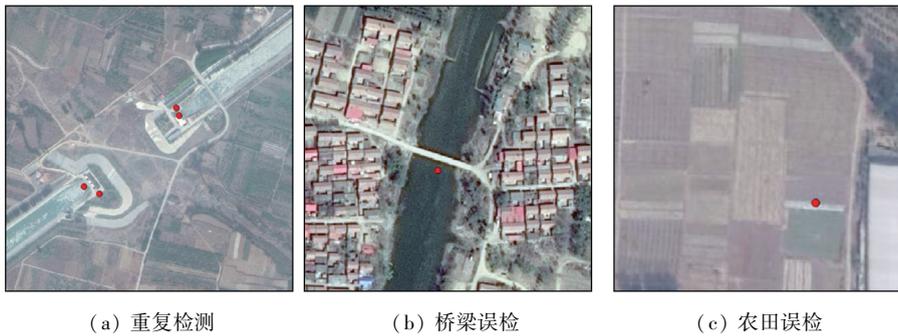


图 8 典型问题示意图

Fig.8 Schematic diagram of typical problems

整体检测结果如图 9 所示。由图 9 可看出,本文得到的水坝大部分在主要河流区域,也有部分位于平原区。为了更好地评估数据结果,同时参考公开的 GRandD 水坝数据集和 CRD 水库数据集。GRandD 数据集主要是大型水坝,在大清河流域只有 5 处目标,这 5 处水坝在本文的方法中全部被成功识别;而 CRD 水库数据,图 9 中所示为水库中心点,水库主要位于山脉与平原交界附近的山区,与本文得到的水坝点基本重合。由于 CRD 数据集本身的误差,以及部分水库没有建设明显的水坝,因此部分水库点没有在本文方法中被检测出来,共 26 处,尤其集中在东侧接近海洋的区域。部分未检测示意图如图 10 所示。图 10(a)中,该区域不存在明显的水坝,因此没有被检测;而在图 10(b)中,有一个小

型水坝没有被检测出来,属于漏检。从整体上看,公开数据集中的水坝和水库信息与本文结果基本相符,且本文检测到了更多的小型水坝,比现有数据集结构更详细精确。



(a) 无明显水坝的水库 (b) 有小型水坝的水库

图 10 本文未检测到的 CRD 水库区示意图

Fig.10 Schematic diagram of CRD reservoir not detected in this paper

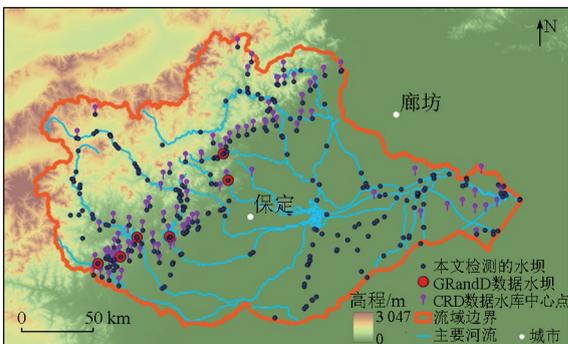


图 9 大清河流域水坝检测结果示意图

Fig.9 Detection results of water conservancy facilities in the Daqing River basin

4 结论

本文基于大清河流域数据研究了大区域的水坝信息检测。通过将桥梁样本设置为难分负样本参与训练,降低桥梁信息对水坝检测的干扰。研究包括 2 个阶段,第一阶段研究检测水坝以及负样本桥梁的网络结构,基于 CenterNet 网络,结合桥梁和水坝目标的特点,进行了以下改进: ①编码器中加入空间注意力机制模块; ②融入调整后的 U-Net 网络结

构,强化特征编码器-解码器之间的连接;③调整边界框形状损失值的权重;④结合 NMS 处理得到了改进后的 U-CenterNet 网络结构。第二阶段,结合 DIOR 数据集中的桥梁与水坝的训练模型参数与大清河流域的样本,引入新疆水坝样本作为扩充样本集,进行大清河流域的水坝检测。

实验结果表明,本文提出的方法可以有效避免桥梁和水坝的混淆,水坝检测 F1 分数达 0.783。在大清河流域的水坝检测实践中,得到水坝目标 330 处,该结果比目前的水坝或水库等公开资料更为详细精确。本文的研究在结合桥梁难分样本的基础上实现了完整区域的水坝提取实践,体现了算法的实际应用价值。

但结果仍然存在一定的漏检、误检问题,一个重要原因是由于整个流域空间范围大,影像光谱和空间特征不一致,因此针对这些特点进行优化是下一步的研究方向。

参考文献 (References):

- [1] 许莹,张友静,张琴.基于高分影像的水利空间要素提取规则集构建[J].地理空间信息,2016,14(5):71-74,7.
Xu Y,Zhang Y J,Zhang Q.Rule sets building of water conservancy facilities spatial element extraction based on high resolution remote sensing image[J].Geospatial Information,2016,14(5):71-74,7.
- [2] 朱然.大数据量复杂背景下桥梁水坝目标快速识别[D].成都:电子科技大学,2015.
Zhu R.Fast recognition of bridge and dam in complex background through masses of data[D].Chengdu:University of Electronic Science and Technology of China,2015.
- [3] 孙宇,黄亮,赵俊三,等.结合随机擦除和 YOLOv4 的高空间分辨率遥感影像桥梁自动检测[J].自然资源遥感,2022,34(2):97-104.doi:10.6046/zrzyyg.2021130.
Sun Y,Huang L,Zhao J S,et al.High spatial resolution automatic detection of bridges with high spatial resolution remote sensing images based on random erasure and YOLOv4[J].Remote Sensing for Natural Resources,2022,34(2):97-104.doi:10.6046/zrzyyg.2021130.
- [4] 邱丹丹,马洪超,杨耘,等.基于多源卫星图像融合的水坝检测方法的研究[J].遥感学报,2006,10(4):449-455.
Qiu D D,Ma H C,Yang Y,et al.A study of dam detection based on multi-source satellite images fusion[J].National Remote Sensing Bulletin,2006,10(4):449-455.
- [5] Redmon J,Divvala S,Girshick R,et al.You only look once: Unified,real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).Las Vegas, NV,USA.IEEE,2016:779-788.
- [6] Redmon J,Farhadi A.YOLOv3: An incremental improvement[J/OL].arXiv,2018.http://arxiv.org/abs/1804.02767.pdf.
- [7] Liu W,Anguelov D,Erhan D,et al.SSD:Single shot MultiBox detector[C]//European Conference on Computer Vision. Cham: Springer,2016:21-37.
- [8] Ren S,He K,Girshick R,et al.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.
- [9] 郭进祥,刘立波,徐峰,等.基于 YOLO v3 的机场场面飞机检测检测方法[J].激光与光电子学进展,2019,56(19):191003.
Guo J X,Liu L B,Xu F,et al.Airport scene aircraft detection method based on YOLO v3[J].Laser & Optoelectronics Progress,2019,56(19):191003.
- [10] 戴伟聪,金龙旭,李国宁,等.遥感图像中飞机的改进 YOLOv3 实时检测算法[J].光电工程,2018,45(12):180350.
Dai W C,Jin L X,Li G N,et al.Real-time airplane detection algorithm in remote-sensing images based on improved YOLOv3[J].Opto-Electronic Engineering,2018,45(12):180350.
- [11] 王文胜.宽幅光学遥感图像舰船飞机目标检测识别技术研究[D].长春:中国科学院大学(中国科学院长春光学精密机械与物理研究所),2018.
Wang W S.Research on technology of ship and aircraft targets recognition from large-field optical remote sensing image[D].Changchun:Changchun Institute of Optics,Fine Mechanics and Physics, Chinese Academy of Sciences,2018.
- [12] 王彦情,马雷,田原.光学遥感图像舰船目标检测与识别综述[J].自动化学报,2011,37(9):1029-1039.
Wang Y Q,Ma L,Tian Y.State-of-the-art of ship detection and recognition in optical remotely sensed imagery[J].Acta Automatica Sinica,2011,37(9):1029-1039.
- [13] 种劲松.合成孔径雷达图像舰船目标检测算法与应用研究[D].北京:中国科学院研究生院(电子学研究所),2002.
Zhong J S.A study on the algorithm of ship target detection in SAR imagery and its applications[D].Beijing:Graduate School of Chinese Academy of Sciences(Institute of Electronics),2002.
- [14] 孙秉义,文珊珊,吴昊,等.基于深度学习的高分辨率遥感图像车辆检测[J].东华大学学报(自然科学版),2018,44(4):520-525.
Sun B Y,Wen S S,Wu H,et al.Vehicle detection in high-resolution remote sensing images based on deep learning[J].Journal of Donghua University (Natural Science),2018,44(4):520-525.
- [15] 冯素婷,盛智勇,后兴海,等.基于旋转框回归的 YOLOV5 遥感图像车辆目标检测[C]//第十五届全国信号和智能信息处理与应用学术会议论文集.北京:计算机工程与应用,2022:4.
Feng S T,Sheng Z Y,Hou X H,et al.Vehicle target detection in YOLOV5 remote sensing image based on rotating box regression [C]// Anthology of the 15th National Academic Conference on Signal and Intelligent Information Processing and Application, Beijing:Computer Engineering and Applications,2022:4.
- [16] 刘康.高分遥感影像建筑目标检测技术研究[D].西安:中国科学院大学(中国科学院西安光学精密机械研究所),2021.
Liu K.Research on building detection technology of the high-resolution remote sensing images[D].Xi'an:Xi'an Institute of Optics and Precision Mechanics,Chinese Academy of Sciences,2021.
- [17] 王玉龙,蒲军,赵江华,等.基于生成对抗网络的地面新增建筑检测[J].计算机应用,2019,39(5):1518-1522.
Wang Y L,Pu J,Zhao J H,et al.Detection of new ground buildings based on generative adversarial network[J].Journal of Computer Applications,2019,39(5):1518-1522.

- [18] Jing M, Cheng L, Ji C, et al. Detecting unknown dams from high-resolution remote sensing images: A deep learning and spatial analysis approach[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 104: 102576.
- [19] 许泽宇, 沈占锋, 李杨, 等. 结合 E-YOLO 和水体指数约束的大面幅影像水利设施检测[J]. *遥感学报*, 2022, 26(10): 2083-2093.
- Xu Z Y, Shen Z F, Li Y, et al. Detection of water conservancy facilities in large-format image combining E-YOLO algorithm and NDWI constraint[J]. *National Remote Sensing Bulletin*, 2022, 26(10): 2083-2093.
- [20] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//*Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*. ACM, 2014: 580 - 587.
- [21] 张焯, 许艇, 冯定忠, 等. 基于难分样本挖掘的快速区域卷积神经网络目标检测研究[J]. *电子与信息学报*, 2019, 41(6): 1496-1502.
- Zhang Y, Xu T, Feng D Z, et al. Research on faster RCNN object detection based on hard example mining[J]. *Journal of Electronics & Information Technology*, 2019, 41(6): 1496-1502.
- [22] 许悦雷, 朱明明, 马时平, 等. 迁移学习结合难分样本挖掘的机场目标检测[J]. *西安电子科技大学学报*, 2018, 45(5): 190-196.
- Xu Y L, Zhu M M, Ma S P, et al. Airport object detection combining transfer learning and hard example mining[J]. *Journal of Xidian University*, 2018, 45(5): 190-196.
- [23] 马广阔. 遥感图像桥梁目标检测方法研究[D]. 呼和浩特: 内蒙古工业大学, 2021.
- Ma G K. Research on bridge target detection method in remote sensing image[D]. Hohhot: Inner Mongolia University of Technology, 2021.
- [24] Zhou X, Wang D, Krähenbühl P. Objects as points[J/OL]. arXiv, 2019. <http://arxiv.org/abs/1904.07850.pdf>.
- [25] 李硕, 沈占锋, 刘克俭, 等. 大清河流域土地利用变化的地形梯度效应分析[J]. *农业工程学报*, 2021, 37(5): 275-284.
- Li S, Shen Z F, Liu K J, et al. Analysis of terrain gradient effects of land use change in Daqing River basin[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(5): 275-284.
- [26] Li K, Wan G, Cheng G, et al. Object detection in optical remote sensing images: A survey and a new benchmark[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 159: 296-307.
- [27] Lehner B, Liermann C R, Revenga C, et al. High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management[J]. *Frontiers in Ecology and the Environment*, 2011, 9(9): 494-502.
- [28] Song C, Fan C, Zhu J, et al. A comprehensive geospatial database of nearly 100 000 reservoirs in China[J]. *Earth System Science Data*, 2022, 14(9): 4017-4034.
- [29] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4): 541-551.
- [30] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J/OL]. arXiv, 2014(2014-09-04) [2023-05-23]. <https://arxiv.org/abs/1409.1556>.
- [31] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]//*International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, 2015: 234-241.
- [32] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//*2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA. IEEE, 2016: 770-778.
- [33] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [34] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//*2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Vancouver, BC, Canada. IEEE, 2023: 7464-7475.
- [35] Girshick R. Fast R-CNN[C]//*2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago, Chile. IEEE, 2015: 1440-1448.
- [36] 李大伟. 固定翼无人机地面车辆目标自动检测与跟踪[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2017.
- Li D W. Automatic vehicle detection and tracking in aerial images by fixed-wing UAV[D]. Beijing: National Space Science Center, Chinese Academy of Sciences, 2017.
- [37] 王金传, 谭喜成, 王召海, 等. 基于 Faster R-CNN 深度网络的遥感影像目标识别方法研究[J]. *地球信息科学学报*, 2018, 20(10): 1500-1508.
- Wang J C, Tan X C, Wang Z H, et al. Faster R-CNN deep learning network based object recognition of remote sensing image[J]. *Journal of Geo-Information Science*, 2018, 20(10): 1500-1508.

Remote sensing-based detection of dams in the Daqing River basin through optimization using hard negative samples of bridges

GUO Yong¹, ZHANG Linxiang¹, XU Zeyu², CAI Zhongxiang¹

(1. Geospatial Information Institute, Information Engineering University, Zhengzhou 450052, China; 2. National Engineering Research Center for Geomatics, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100101, China)

Abstract: The dam detection is crucial for urban planning, ecological environment assessment, and other purposes. Currently, research on remote-sensing-based dam detection mainly focuses on algorithm improvements using

sample sets or small-scale localized detections, with a significant gap in practical applications over large-scale geographical regions. In large-scale regions, the sparse distribution of dams, along with the presence of more surface features such as bridges, significantly interferes with dam detection. To address this issue, this study explored the Daqing River basin as a case study to investigate remote sensing methods for dam detection in large-scale regions. This study consisted of two main phases. In the first stage, bridges, which are easily confused with dams, are considered hard negative samples (i.e., samples prone to false positives) for training. The neural network structure suitable for dam detection was improved based on the DIOR open dataset. In the second phase, the detection model was developed through fine-scale tuning using the optimized network alongside multi-source sample data from the large Daqing River basin. Concurrently, dams within the Daqing River region were detected. The optimized model yielded dam detection F1 of 0.783 in the first phase of tests and identified 330 dams in the Daqing River basin during the second phase. These results align with the existing publicly available dam spatial distribution dataset GRandD, even providing more details. The results of this study indicate that the model, optimized using bridge samples, can effectively mitigate the incorrect extraction of bridges, thereby improving detection accuracy.

Keywords: dam; hard negative samples; Daqing River basin; CenterNet; object detection

(责任编辑: 张仙)