文章编号:1005-0523(2025)02-0103-07

基于实例分割的填埋场渗漏源检测算法研究

陈强华,黎　明

(上海电机学院电子信息学院,上海 201306)

摘要:渗漏源检测是保障危险废物填埋场正常运行的重要措施,传统的人工目视检测效率低且危险废物会影响巡检人员的身体健康。使用一种基于实例分割的方法检测渗漏源。通过巡检机器人搭载的相机采集画面,采用YOLOSeg-EViT网络进行实例分割。实验结果表明,该算法的平均精度为75.7%,使用分辨率为1 280×720像素的视频进行检测时,检测的帧率为54.4 帧/s。在边缘计算平台中,该算法的平均精度为75.1%,帧率为33.1 帧/s。该算法可以有效检测渗漏源,提升检测效率,避免巡检人员接触有害物质,具有实用价值。

关键词:填埋场渗漏源;缺陷检测;实例分割;深度学习;轻量化部署

中图分类号::TP 391.41　　**文献标志码:**A

本文引用格式:陈强华,黎明. 基于实例分割的填埋场渗漏源检测算法研究[J]. 华东交通大学学报,2025,42(2):103-109.

Research on the Detection Algorithm for Landfill Leakage Based on Instance Segmentation

Chen Qianghua, Li Ming

(School of Electronic Information Engineering, Shanghai Dianji University, Shanghai 201306, China)

Abstract: Leakage detection is a critical measure to ensure the proper operation of hazardous waste landfills. Traditional manual visual inspections are inefficient, and hazardous waste can affect the health of workers.A method based on instance segmentation is proposed to detect leakage. The method uses a camera mounted on an inspection robot to capture video images, the YOLOSeg-EViT network performs instance segmentation. Experimental results show that the algorithm achieves a mean average precision of 75.7%, and when detecting with a 1 280×720 pixel resolution video, the detection is 54.4 frames per second. On an edge computing platform, the algorithm reaches mean average precision 75.1% and 33.1 frames per second. The leakage detection algorithm effectively identifies leakage, improves the detection efficiency, and prevents workers from being exposed to hazardous substances, making it highly practical.

Key words: landfill leakage; defect detection; instance segmentation; deep learning; lightweight deployment

Citation format: CHEN Q H, LI M. Research on the detection algorithm for landfill leakage based on instance segmentation[J]. Journal of East China Jiaotong University, 2025, 42(2): 103-109.

危险废物填埋场是处置危险废物的一种陆地　　处置设施,其功能为隔断危险废物中重金属等有害

收稿日期:2024-10-29

组分向环境和人体迁移的途径，从而安全处置危险废物[1]。填埋场渗漏检测对确保设施正常运行、防止事故发生、降低潜在的安全风险具有重要意义。

在填埋场渗漏检测的应用中，刘景财等[2]在填埋场四周布设电极，利用集成开发的边界定位检测系统计算获取的信号，最终给定渗漏源的GPS坐标和数据可视化结果。在渗漏检测的应用中，Ali等[3]通过对用水量以及耗水量的对比，依据能量守恒的原则判断是否产生渗漏。Lyu等[4]提出了一种基于视觉背景提取器（visual background extractor，ViBe）和EfficientNetB0的渗漏检测系统，使用基于EfficientNetB0的卷积神经网络（convolutional neural networks，CNN）模型排除环境干扰、检测出泄露区域。使用传感器检测渗漏的方法多用于管道类检测，危险废物填埋场面积较大，传感器部署较为困难。

随着计算机计算能力的提升，计算机视觉的检测方法被广泛应用于缺陷检测。常用的计算机视觉检测方法可以分为图像分类、目标识别以及实例分割。在图像分类的方法中，Park等[5]使用由分割和分类模块组成的卷积神经网络模型执行分割处理，将道路区域分为裂缝、道路标记和完整区。目标检测的方法使用边界框识别图像中的目标。Ju等[6]使用CNN来提取深度特征的同时使用灵敏度检测网络，提出了一种Faster R-CNN[7-8]改进版本裂纹检测方法。Su等[9]设计了MOD-YOLO[10]算法，并将其应用于民用基础设施中的裂纹检测。Maeda等[11]采用单次多框检测（single shot multibox detector，SSD）[12]框架在综合数据集中执行裂纹检测，他们利用Inception V2和MobileNet作为SSD框架中的骨干特征提取器模块。实例分割是目标检测和语义分割的结合，可以同时输出渗漏源的种类、位置和形状。Gao等[13]基于U-Net，提出了一种基于U-Net的ARD-Unet用于检测道路裂缝。Liu等[14]通过CNN模型改变U-Net的编码器，提出了一种更准确、高效的裂纹检测模型，并集成视觉解释来解释该模型。

填埋场需要巡检的面积较大，因此需要检测速度较快的实例分割网络提升渗漏源检测效率。实时实例分割网络（you only look at coefficients，YOLACT）[15]将整体的实例分割任务分为检测与分割两个并行任务，完成两个并行任务后的输出融合为最终的检测结果。按位置分割网络（segmenting objects by locations，SOLO）[16]通过去除量化步骤，在保持精度不变的情况下，提升网络的运算速度。

针对填埋场的应用场景，本文提出一种轻量化实例分割网络YOLOSeg-EViT进行填埋场渗漏源检测。

1 方法

危险废物填埋场的鸟瞰图如图1（a）所示，填埋场渗漏源的检测位置为填埋场底部，渗漏源包括已经产生的渗漏以及具有渗漏隐患的裂缝。填埋场底部如图1（b）所示。



（a）填埋场鸟瞰图　　（b）填埋场底部图

图1 填埋场现场图

Fig. 1 Images of landfill site

1.1 整体检测流程

如图2所示为方法流程图。首先，使用巡检机器人搭载带有红外补光的可见光相机进行视频采集。巡检机器人搭载两台相机，分别采集前向与后向的画面，相机搭载方式如图2中红框放大部分所示。两台相机采集视频的分辨率为1 280×720像素，采集视频的帧率F为6 帧/s。其次，对待测视频进行实例分割，获得具有掩膜标记的渗漏源检测结果。然后，生成渗漏源检测报告，报告中包含渗漏源的检测图像以及对应坐标信息。一份检测报告的示例如图2中检测报告示例所示，其中：坐标信息图中的位置信息从巡检机器人中调出，原点位置是巡检机器人的出发位置；x，y表示与出发点之间的方向距离，m；红色三角形表示渗漏源位置。

1.2 基于实例分割的YOLOSeg-EViT网络

巡检单个填埋池采集的待测视频时长为30 min，且每次巡检会检查多个填埋池。为了提升渗漏源的检测效率，本研究提出一种基于实例分割的YOLOSeg-EViT网络用于快速检测待测视频。该网络由骨干网络，颈部以及检测头构成。骨干网络会对输入图像进行特征提取操作，并将提取到的信息进行处理之后传递到下一个阶段[17]。骨干网络的特征提取与处理方式会影响网络的检测速度，提升检测速度的一种方式为使用轻量化的骨干网络。

骨干网络中添加EfficientViT用于提升信息提

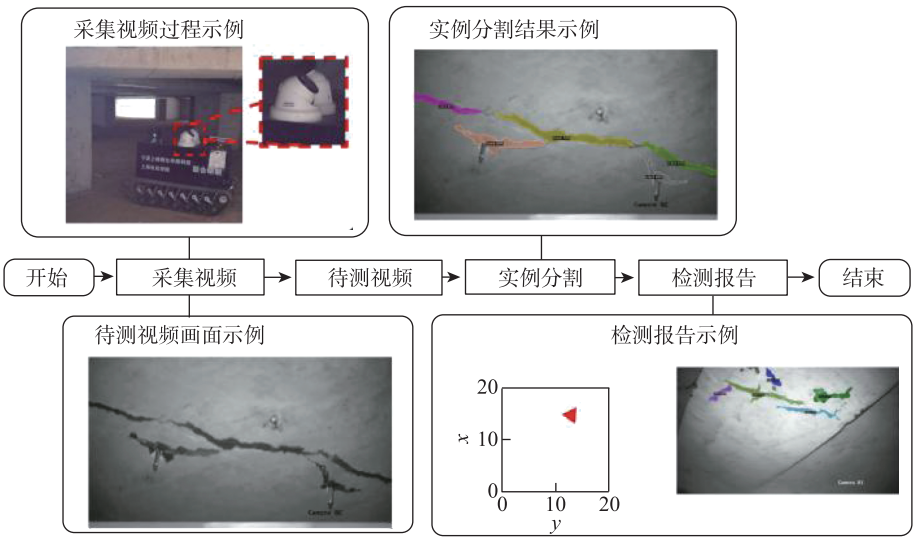


图2　方法流程图

Fig. 2　Picture of landfill site

取的速度，EfficientViT是一个轻量级多尺度注意力的图像分割模型，它通过线性注意力代替softmax注意力并通过深度卷积增强局部特征提取能力，从而实现全局感受野和多尺度学习[18]。EfficientViT具有三明治结构，输入的特征首先经过N个前馈神经网络（feedforward neural network，FFN），其次经过1个级联组注意力模块（cascaded group attention，CGA），再经过N个FFN变换得到输出特征。在FFN中，EfficientViT采用单个受内存限制的多头自注意力机制（multi-head self-attention，MHSA），缓解了注意力计算导致的访存时间消耗问题，实现网络轻量化。骨干网络将提取的特征按不同尺度分级输出，减少计算冗余的同时增加网络学习特征的多样性。EfficientViT不仅有效减少了骨干网络的参数量，也保证了网络的检测精度。

YOLOSeg-EViT网络结构图如图3所示。图3中C1的输入尺寸为80×80×256以及80×80×512，输出尺寸为80×80×768；C2的输入尺寸和输出尺寸都为40×40×512；C3的输入尺寸为40×40×256以及40×40×512，输出尺寸为40×40×768；C4的输入尺寸和输出尺寸都为20×20×512。网络中使用3个不同尺寸的检测头，用于生成检测结果以及对特征图进行分类。ConvBlock为深度学习模块，SPPF为快速空间金字塔池模块，Loss为损失模块。

2　实验

2.1　实验数据

数据集中的填埋场渗漏源分为3类。第1类为裂缝（crack），裂缝类别的一个实例如图4(a)所示。裂缝的几何特征为狭长的条状；第2类为破损（breakage），破损的特征为块状碎裂，破损的几何特征不规则，破损类别的一个实例如图4(b)所示。第3类为渗漏（leakage），渗漏的特征为颜色较深，在混凝土墙体上呈现出在水平墙面扩散渗漏或沿着垂直墙面向下渗漏，渗漏类别的一个实例如图4(c)所示。

算法的数据集为YOLO数据集格式，数据集的标注方式为使用分割一切模型（segment anything model，SAM）进行半自动标注。SAM可以对输入图像进行零样本泛化，根据输入点等输入提示生成高质量的对象掩膜[19]。在标注时，首先使用SAM对数据集图像进行特征提取操作，操作完成后会根据图像的提取结果生成若干个掩膜；其次选中渗漏源的掩膜并保存到标签文件中；然后采用LabelMe标注工具对SAM生成的实例掩膜进行手动校正。数据集生成过程中主要步骤示意图如图5所示。

本研究的训练集中类别crack，breakage，leakage分别有4 345，705，493个实例。验证集中类别crack，breakage，leakage分别有1 931，328，189个实例，训练集与验证集中的实例相互独立。

2.2　实验细节

实验中PC机使用的CPU为Intel i9-11900KF，GPU为NVIDIA A40（48 GB），系统为Ubuntu20.04，Python版本为3.8，Cuda版本为11.1，PyTorch版本为1.10.1。边缘计算平台为Jetson AGX Orin，系统为Ubuntu20.04，Python版本为3.8，Cuda版本为

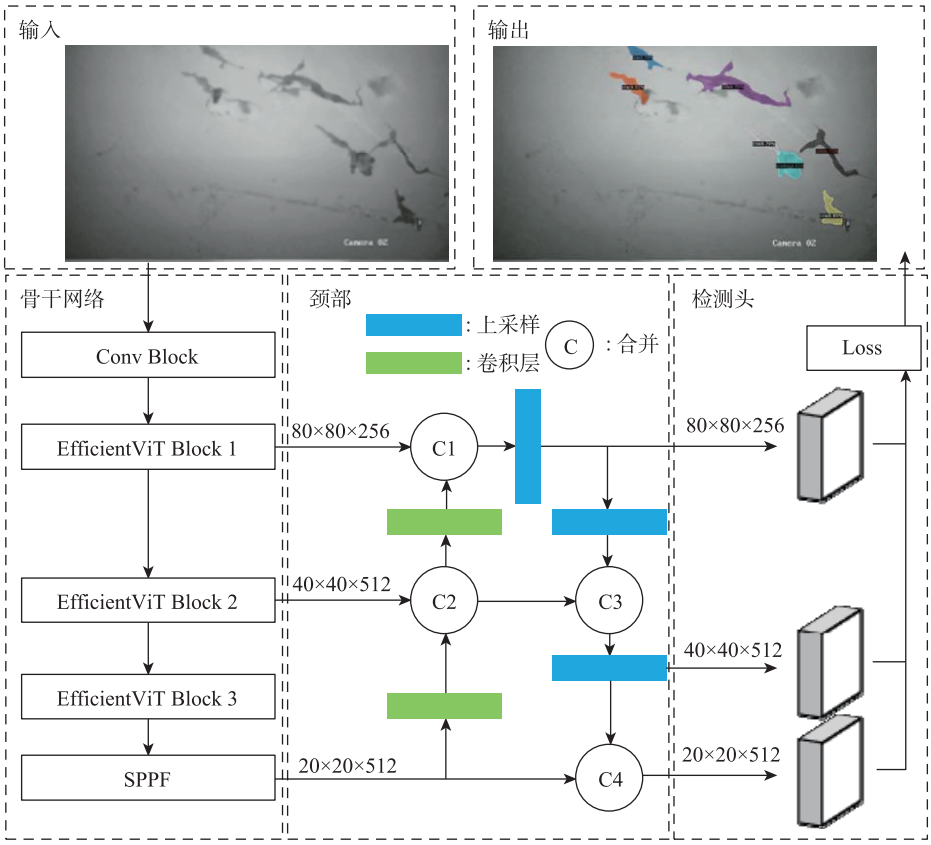


图3 YOLOSeg-EViT网络结构图

Fig. 3 Diagram of YOLOSeg-EViT network architecture



（a）Crack实例 （b）Breakage实例 （c）Leakage实例

图4 填埋池渗漏源实例图

Fig. 4 Example diagram of landfill leakage

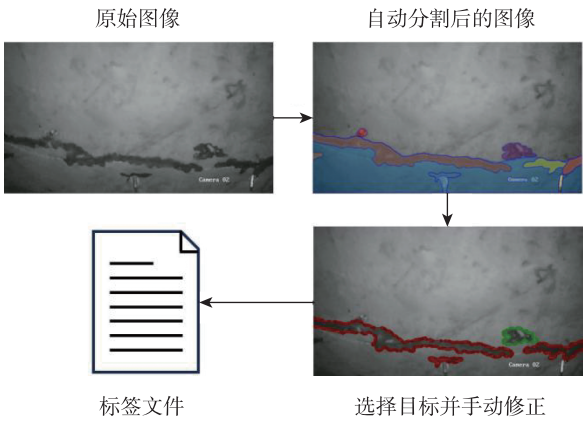


图5 数据集生成过程示意图

Fig. 5 Main process diagram of dataset annotation

11.4，PyTorch版本为1.12.0。网络训练时的训练轮数设置为300轮。PC机训练网络时batchsize默认设置为64，边缘计算平台训练网络时batchsize默认设置为32，训练与检测时网络输入图像的尺寸都为640×640像素。

2.3 实验评价指标

实例分割的结果通常可以划分为4类：真正例 P_T，假正例 P_F，真负例 N_T，假负例 N_F。准确率 P 和召回率 R 的计算方法如

$$P=\frac{P_T}{P_T+P_F} \tag{1}$$

$$R=\frac{P_F}{P_F+N_F} \tag{2}$$

平均精度 P_A 计算方法如

$$P_A=\frac{1}{N}\sum_{i=1}^{N}P(R_i) \tag{3}$$

式中：N为计算插值或积分时需要的不同R点数量；文中N=11，该取值参考了PASCAL VOC挑战中N的数值，在0~1中等间隔取值；R_i为第i个召回率；$P(R_i)$为在第i个召回率下的准确率。P_{mA}为所有

类别 P_A 的平均值，用于反映整个模型的准确率，实验使用各类别的 P_A 与整体的 P_{mA} 指标衡量网络检测精度。

2.4　实验结果

为了评价 YOLOSeg-EViT 网络对渗漏源检测的有效性，使用训练集对网络进行训练，网络完成训练后会生成一个预训练模型。使用预训练模型在验证集中检测，验证过程为预训练模型检测结果与标签文件的真值进行对比。

2.4.1　YOLOSeg-EViT 实验结果

本论文中 PC 机实验环境下 YOLOSeg-EViT 网络使用自建数据集的最终迭代结果如表 1 所示。

表 1　YOLOSeg-EViT 网络训练结果

Tab.1　Training results of YOLOSeg-EViT network

内容	数值
P_A-crack/%	81.1
P_A-breakage/%	66.7
P_A-leakage/%	79.2
P_{mA}/%	75.7
网络参数/($\times 10^6$ 个)	28.2
F/(帧/s)	54.4

由表 1 可知，YOLOSeg-EViT 网络对 crack 类别实例以及 leakage 类别实例的检测准确度较高，而对 breakage 类别实例的检测准确度较低，这与三类渗漏源的特征相符合。crack 类别实例与 leakage 类别实例的形状较为单一，网络在训练时可以较为容易地学习这类渗漏源的特征。breakage 类别实例的形状与大小没有特定规律，网络在学习 breakage 类别实例的特征时较为困难。一些 breakage 类别实例位于尺寸较大的裂缝中，算法在检测时会把整个渗漏源区域归类为 crack 类别。网络的 F 值为 54.4 帧/s，具有较快的推理速度。一张的网络分割效果图如图 6 所示。

由图 6 可知，YOLOSeg-EViT 实例分割算法可以有效地分割出图中渗漏源，并使用不同颜色的掩膜区分不同的渗漏源，具有良好的检测效果。同时，渗漏源检测的过程中未受到混凝土墙体污渍（图 6 中红色方框区域）以及修补模头（图 6 中黄色方框区域）的干扰，具有较好的抗干扰能力。

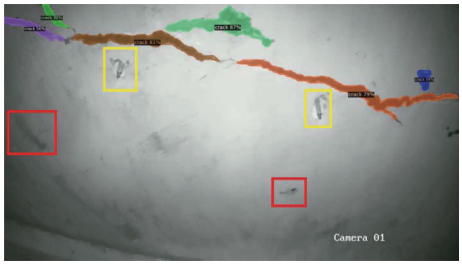


图 6　实例分割效果图

Fig. 6　Example diagram of instance segmentation

2.4.2　对比实验

为了进一步验证网络的效果，使用 MASK R-CNN[8] 网络，YOLOv8-seg 网络进行对比实验，实验时的实验环境与数据集完全相同。为了直观展示 YOLOSeg-EViT 网络与 YOLOv8-seg 网络的对比效果，对比实验中将 YOLOSeg-EViT 与 YOLOv8-seg 网络的小尺寸 s、中尺寸 m、大尺寸 l、超大尺寸 x 进行对比，并在对比时调整 YOLOSeg-EViT 网络的深度因子（deepen factor）、宽度因子（widen factor）和比例（ratio）与对应的 YOLOv8 网络相同。例如，表 2 中本文网络（s）表示网络的深度因子、宽度因子和比例与 YOLOv8s-seg 相同。YOLOv8-seg 使用对应尺寸的预训练权重进行初始化，对比实验结果如表 2 所示。

由表 2 可知，YOLOSeg-EViT 的 P_{mA} 以及 F 高于 MASK R-CNN。对比 YOLOv8-seg 各尺寸时，YOLOSeg-EViT 网络的训练效果要优于对应尺寸的 YOLOv8-seg 网络。虽然使用较小尺寸的网络可以提升 F，但是较小尺寸网络的检测精确度较低，可能会造成漏检从而使渗漏源进一步扩大。YOLOSeg-EViT 网络参数小于 MASK R-CNN 以及对应尺寸的 YOLOv8-seg 网络参数，说明网络轻量化的有效性。

2.4.3　边缘计算平台部署结果

为了验证 YOLOSeg-EViT 在边缘计算平台上的效果，使用 YOLOv8l-seg 进行对比实验，实验结果如表 3 所示。

由表 3 可知，YOLOSeg-EViT 在边缘计算平台上平均准确率高于 YOLOv8l-seg。虽然 PC 机的 F 较高，但是边缘计算平台成本更低，且边缘计算平台可以直接部署于巡检机器人，无需调出待测视频便可完成检测，提高填埋场渗漏源的检测效率。

2.4.4　实验误差分析

在实验结果中，breakage 类别的检测精度较低，该类别的边缘并不固定，算法在检测时赋予的掩膜边缘与真值会存在一定差异，从而造成数值降低。一张实例图如图 7 所示，网络虽然成功检测出 breakage 实例，但是检测边缘与真值存在一些差异。

在检测 crack 类别时，一些 crack 类别较为细长。此时算法可能会将一条细长的裂缝检测为两条裂缝，一张实例图如图 8 所示，图 8 在原始图像与检测结果中放大了细长裂缝中较为细小的部分。

在 leakage 类别的检测中，由于 leakage 在水平

表2 对比实验结果

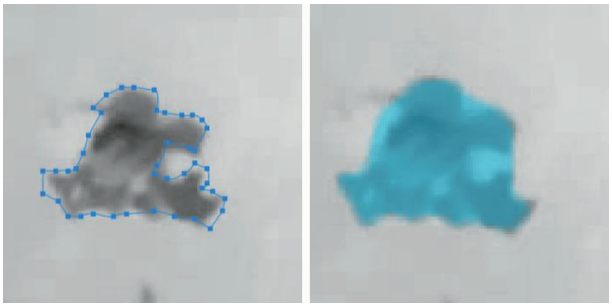
Tab.2 Results of comparison experiments

网络名称	P_A-crack/%	P_A-breakage/%	P_A-leakage/%	P_{mA}/%	网络参数/(×10⁶个)	F/(帧/s)
MASK R-CNN	73.2	62.1	71.4	68.9	41.3	31.2
YOLOv8s-seg	79.7	65.5	75.9	73.7	11.7	53.5
本文网络(s)	80.9	66.0	75.5	74.1	9.0	61.1
YOLOv8m-seg	78.2	61.3	76.3	72.0	27.2	52.9
本文网络(m)	80.8	62.9	78.8	74.2	17.7	56.3
YOLOv8l-seg	79.5	63.9	70.5	71.3	45.9	44.4
本文网络(l)	81.1	66.7	79.2	75.7	28.2	54.4
YOLOv8x-seg	76.5	61.9	72.1	70.2	71.7	39.5
本文网络(x)	79.1	63.6	69.5	70.7	42.8	48.0

表3 边缘计算平台结果

Tab.3 Results of Edge computing platform

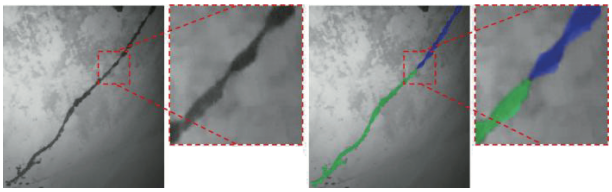
内容	YOLOv8l-seg	本文网络
P_A-crack/%	79.8	81.0
P_A-breakage/%	63.9	65.4
P_A-leakage/%	70.9	79.0
P_{mA}/%	71.5	75.1
网络参数/(×10⁶个)	45.9	28.2
F/(帧/s)	31.0	33.1



(a) Breakage 实例真值图像 (b) Breakage 实例检测图像

图7 Breakage类别检测示例图

Fig. 7 Example diagram of breakage detection



(a) 原始图像 (b) 检测结果

图8 Crack类别检测示例图

Fig. 8 Example diagram of crack detection

墙面扩散渗漏或沿着垂直墙面向下渗漏的特征较为相似,且与混凝土墙体具有高对比度,网络对leakage类别的渗漏源具有很好的检测效果。

虽然实验中检测breakage类别与crack类别时生成的掩膜与真实结果存在一些差异,但是并没有产生漏检。同时,这些掩膜的差异不会对后续的养护方式产生影响。

3 结论

本文使用一种YOLOSeg-EViT实例分割网络算法进行填埋场渗漏源检测,该算法的骨干网络中添加了轻量级多尺度注意力的图像分割模块EfficientViT,实验中获得以下结论。

1)使用自建的填埋场渗漏源数据集进行训练时,YOLOSeg-EViT的P_{mA}为75.7%,检测1 280×720像素分辨率视频的F为54.4 帧/s,可以实现高效率的填埋场渗漏源检测。

2)该算法可以部署到便携性更好的边缘计算平台上,P_{mA}为75.1%,F为33.1帧/s。

3)该算法可以有效检测渗漏源,具有一定的实用价值;同时,该算法可以为其他领域的特征分割问题提供参考和启发。

参考文献:

[1] 郑伟, 金晶, 王清森, 等. 生活垃圾填埋场渗滤液全量化处理工艺设计及应用[J]. 绿色科技, 2024, 26(6): 181-185.
ZHENG W, JIN J, WANG Q S, et al. Design and case analysis of fully quantitative treatment process for leachate from a domestic waste landfill[J] Journal of Green Science and Technology, 2024, 26(6): 181-185.

[2] 刘景财, 孙晓晨, 郑开达, 等. 基于边界定位法的固体废物填埋场渗漏应急检测技术及应用[J]. 环境工程技术学报, 2022, 12(6): 1978-1984.
LIU J C, SUN X C, ZHENG K D, et al. Emergency detection technology and application of solid waste landfill leakage based on boundary positioning method[J] Journal of Environmental Engineering Technology, 2022, 12(6): 1978-1984.

[3] ALI A S, ABDELMOEZ M N, HESHMAT M, et al. A solution for water management and leakage detection problems using IoTs based approach[J]. Internet of Things, 2022, 18: 100504.

[4] LYU C, LIU Y, WANG X, et al. Visual early leakage detection for industrial surveillance environments[J]. IEEE Transactions on Industrial Informatics, 2021, 18(6): 3670-3680.

[5] PARK S, BANG S, KIM H, et al. Patch-based crack detection in black box images using convolutional neural networks[J]. Journal of Computing in Civil Engineering, 2019, 33(3): 04019017.

[6] JU H Y, LI W, TIGHE S, et al. Detection of sealed and unsealed cracks with complex backgrounds using deep convolutional neural network[J]. Automation in Construction, 2019, 107: 102946.

[7] REN S, HE K, GIRSHICK R, et al. Faster r-Cnn:towards real-time object detection with region proposal networks [J]. Advances in neural information processing systems, 2015, 28: 1137-1149.

[8] BHARATI P, PRAMANIK A. Deep learning techniques: R-CNN to mask R-CNN: a survey[J]. Computational Intelligence in Pattern Recognition, 2019, 999: 657-668.

[9] SU P, HAN H, LIU M, et al. MOD-YOLO:Rethinking the YOLO architecture at the level of feature information and applying it to crack detection[J]. Expert Systems with Applications, 2024, 237: 121346.

[10] BADGUJAR C M, POULOSE A, GAN H. Agricultural object detection with you only look once(YOLO) algorithm: a bibliometric and systematic literature review[J]. Computers and Electronics in Agriculture, 2024, 223: 109090.

[11] KUMAR A, SRIVASTAVA S. Object detection system based on convolution neural networks using single shot multi-box detector[J]. Procedia Computer Science, 2020, 171: 2610-2617.

[12] MAEDA H, SEKIMOTO Y, SETO T, et al. Road damage detection and classification using deep neural networks with smartphone images[J]. Computer Aided Civil and Infrastructure Engineering, 2018, 33(12): 1127-1141.

[13] GAO Y, CAO H, CAI W, et al. Pixel-level road crack detection in UAV remote sensing images based on ARD-Unet[J]. Measurement, 2023: 219.

[14] LIU F, WANG L. UNet-based model for crack detection integrating visual explanations[J]. Construction and Building Materials, 2022, 322: 126265.

[15] ZENG J, OUYANG H, LIU M, et al. Multi-scale YOLACT for instance segmentation[J]. Journal of King Saud University-Computer and Information Sciences, 2022, 34(10): 9419-9427.

[16] WANG X,ZHANG R,KONG T, et al. SOLOv2: dynamic and fast instance segmentation[J]. Advances in Neural information processing systems, 2020, 33: 17721-17732.

[17] 董华军, 王宇栖. 基于改进YOLOv5s的无人机小目标检测算法研究[J]. 华东交通大学学报, 2024, 41(4): 118-126.
DONG H J, WANG Y Q. Research on UAV small target detection algorithm based on improved YOLOv5s[J] Journal of East China Jiaotong University, 2024, 41(4): 118-126.

[18] GUO Y, LI Z, LIU F, et al. Fast and lightweight automatic lithology recognition based on efficient vision transformer network[J]. Solid Earth Sciences, 2025, 10(1): 100179.

[19] KE L, YE M, DANELLJAN M, et al. Segment anything in high quality[J]. Advances in Neural Information Processing Systems, 2024, 36: 29914-29934.



第一作者:陈强华(1997—),男,硕士研究生,研究方向为计算机视觉与人工智能。E-mail:226003010201@st.sdju.edu.cn。



通信作者:黎明(1979—),男,副教授,博士,硕士生导师。研究方向为工业机器视觉,人工智能和模式识别。E-mail:mingli@sdju.edu.cn。

(责任编辑:姜红贵)