

基于DFES-YOLOv5s的道路脱空病害智能检测 优化算法研究

杨东宽¹, 高光磊¹, 尹诗雨¹, 荆瑞俊¹, 周丽军², 周晓旭², 穆继亮¹

(1. 中北大学 仪器与电子学院, 山西 太原 030051; 2. 山西省智慧交通实验室有限公司, 山西 太原 030032)

摘要: 脱空作为典型的道路隐伏病害是导致路基塌陷的主要诱因, 智慧交通的发展对快速、高效、准确识别脱空病害提出了极高要求。常用的探地雷达无损检测技术受道路结构层介质复杂和病害形态多变的耦合影响, 存在病害特征提取一致性差和难于辨识等问题。本文以高速公路百公里实测图像数据为真实样本, 提出了一种基于DFES-YOLOv5s的道路脱空病害智能检测算法。针对病害特征形态多变提取难的问题, 基于YOLOv5s模型设计了可变形卷积用以替代C3模块, 从而提升了对多变特征的适应性, 有效提取了病害关键特征; 针对背景干扰信息多的问题, 采用Focal-EIOU损失函数关注高质量锚框, 综合评估宽高差异, 解决了正负样本不均衡和模型收敛难的问题; 针对病害特征与背景噪声高相似性的问题, 加入SimAM注意力机制, 过滤干扰信息, 从而提升模型的目标特征表示和判别的能力。实验结果表明, 本研究所设计的DFES-YOLOv5s检测算法的准确率、平均精度、召回率分别达到84.2%, 88.5%, 84.2%, 相较于常规YOLOv5s算法分别提升了9.7个百分点, 5.3个百分点, 7.0个百分点。该研究为提升道路脱空病害智能化检测水平和工程化推广应用提供了关键技术支撑。

关键词: 脱空; 路基; 探地雷达; DFES-YOLOv5s; 智能检测

中图分类号: TP391 **文献标识码:** A **doi:** 10.62756/jnuc.issn.1673-3193.2024.11.0011

引用格式: 杨东宽, 高光磊, 尹诗雨, 等. 基于DFES-YOLOv5s的道路脱空病害智能检测优化算法研究[J]. 中北大学学报(自然科学版), 2025, 46(4): 499-507.

YANG Dongkuan, GAO Guanglei, YIN Shiyu, et al. Research on optimization algorithm for intelligent detection of road cavity diseases based on DFES-YOLOv5s[J]. Journal of North University of China (Natural Science Edition), 2025, 46(4): 499-507.

Research on Optimization Algorithm for Intelligent Detection of Road Cavity Diseases Based on DFES-YOLOv5s

YANG Dongkuan¹, GAO Guanglei¹, YIN Shiyu¹, JING Ruijun¹, ZHOU Lijun²,
ZHOU Xiaoxu², MU Jiliang¹

(1. School of Instrument and Electronics, North University of China, Taiyuan 030051, China;
2. Shanxi Intelligent Transportation Laboratory Co., Ltd., Taiyuan 030032, China)

Abstract: Cavity as a typical road hidden disease is the main cause of roadbed collapse, the development of intelligent transportation for rapid, efficient and accurate identification of cavity disease put forward high requirements. Commonly used ground-penetrating radar nondestructive testing is affected by the road

收稿日期: 2024-11-20

基金项目: 国家自然科学基金资助项目(52375554)

作者简介: 杨东宽(2000-), 男, 硕士生, 主要从事人工智能和图像处理技术的研究。

通信作者: 穆继亮(1978-), 男, 教授, 博士, 主要从事智能微纳器件与系统的研究。E-mail: mujiliang@nuc.edu.cn.

structural layer of complex media and disease morphology of variable coupling, there are issues such as poor consistency of the disease feature extraction and difficult to recognize. In this paper, we took the 100-kilometer measured image data of the highway as a real sample, and proposed an intelligent detection algorithm of road cavity disease based on DFES-YOLOv5s. To address the difficult problem of extracting features of disease with variable morphology, a deformable convolutional alternative C3 module was designed based on the YOLOv5s model to enhance the adaptability to the variable features, and the key features of the disease were effectively extracted; To address the problem of high similarity between disease features and background noise, the Focal-EIOU loss function was used to focus on high-quality anchor frames and comprehensively evaluate the width-height difference, which solved the problems of positive and negative sample imbalance and difficult model convergence; For the problem of many background interference information, the SimAM attention mechanism was added to filter the interference information to improve the performance of the model in the target feature representation and discrimination ability. Experimental results show that the accuracy, average precision, and recall of the DFES-YOLOv5s detection algorithm designed in this study reach 84.2%, 88.5%, and 84.2%, respectively, which are improved by 9.7, 5.3, and 7.0 percentage points, respectively, compared with the conventional YOLOv5s algorithm. This research provides key technical support for enhancing the intelligent detection level and engineering popularization and application of road cavity disease.

Key words: cavity; roadbed; ground-penetrating radar; DFES-YOLOv5s; intelligent detection

0 引言

随着我国城镇化建设进程的不断推进,城市道路基础设施建设快速发展。受雨水冲刷、车辆载荷、冻土春融等自然力冲击,道路极易因面层、基层、垫层等内部结构层损坏而产生脱空病害。与可视性的道路表面裂纹、龟裂不同,结构层脱空病害具有隐伏特征,若不及时处理会逐渐累积,最终形成路面大面积破损、突然坍塌等深层次灾害,不仅会增加维修成本、引发交通拥堵,更会严重威胁人车安全。因此,提前预测道路隐伏病害,适时开展检测与维护,对延长道路使用寿命和保障交通安全至关重要^[1]。

探地雷达(Ground Penetrating Radar, GPR)是一种利用天线发射和接收高频电磁波来探测介质内部物质特性和分布规律的地球物理方法,具有探测速度快、过程连续、分辨率高等优点,在道路病害检测应用方面操作方便、灵活、无损。目前,道路脱空病害检测主要依靠对探地雷达所获取的图像资料进行人工离线分析和病害辨识。面对智慧交通发展对道路病害的长距、大量、短时、精准检测需求,单纯依靠人工经验和专家机制进行病害识别与标注,难以满足智能化发展要求,亟待开展基于深度学习的道路隐伏病害研究。

相较于需要人工参与特征设计的Hough变换^[2]、

尺度不变特征^[3]、加速稳健特征^[4]等传统机器学习方法,深度学习技术具有更高的识别准确率,并且已广泛应用于公路病害检测中。Kang等^[5]采用UcNet网络对地下物体进行分类,能够在没有专家干预的情况下解释GPR图像数据,识别准确率达88.26%,但存在大量漏检现象,召回率仅为72.36%;江路路等^[6]采用YOLOv5算法对实测和正演模拟生成的GPR图像进行脱空病害自动识别,平均精度为75.9%;Li等^[7]采用V-IOU YOLOv3算法对探地雷达图像的智能检测平均精度为84.56%;Qiu等^[8]采用BiFPN和GIoU改进YOLOv5网络结构来解决GPR检测中存在的误检问题,平均精度为75.7%;Luo等^[9]采用CAPW-YOLO检测隧道衬砌空腔的平均精度为83%。由上分析,对脱空病害检测的平均精度仍待提高。

部分研究者模拟生成GPR图像进行病害识别研究。周中等^[10]通过有限差分域方法生成模拟雷达图像,并使用YOLOv7改进算法对隧道衬砌内部缺陷进行识别,平均精度为74.52%;Omwenga等^[11]采用AC-GPR算法来检测GprMax软件生成的GPR仿真图像数据;Hu等^[12]利用对抗生成网络扩充现有GPR数据集,在YOLOv5算法的基础上增加注意力机制,对脱空病害检测的平均精度达到了87.5%。这类方法仅仅适用于相对均匀的环境,仿真模型很难模拟出真实道路地

下的复杂性和多样性,与实测图像数据存在偏差。

在开放场景下,道路隐伏病害的智能检测受目标形态多变、正负样本不均衡和背景信息复杂等因素影响,存在模型难以有效解析正样本特征和特征提取一致性差等问题。针对上述问题,本文从提升形态多变目标的检测精度以及使模型有效聚焦正样本特征两方面展开研究。

1 数据集构建

1.1 B-SCAN 图像获取

本文所用数据集是在山西高速公路上实测的GPR B-SCAN图像,相较于模拟生成的数据集,其可以更真实地反映地下结构信息。GPR的电磁波工作原理如图 1(a)所示,发射天线向地下发射高频电磁波,在地下介质间发生反射现象,接收机会接收到不同回波信号,经处理生成如图 1(b)所示的二维剖面图,即B-SCAN图像。图中清晰可见明暗不同的线条和边缘不规则的结构,这是由异构路基介质层对雷达电磁波的不同反射所形成的典型图谱,其中也隐含了部分病害特征。




图 1 GPR 成像原理
Fig. 1 GPR imaging principle

1.2 数据增强

在 GPR 图像采集过程中,采集角度和路面高度的不同会改变图像中异常目标的形状,从而影响识别效果。为了提升模型的泛化能力和鲁棒性,本文采用了图像镜像变换和 180° 旋转变换两种数据增强技术对原始数据进行增强,如图 2 和图 3 所示。这使得模型在面对不同方向和视角的

图像时都能够保持较高的识别准确率,同时,该增强策略能够让模型学习到更加泛化的特征,而不仅仅依赖于训练数据中的特定样本,这有助于减少模型过拟合的风险。




图 2 镜像变换
Fig. 2 Mirror transformation




图 3 旋转变换
Fig. 3 Rotation transformation

1.3 脱空标注

电磁波在脱空病害的上下界面射入射出时,脱空区域与混凝土层之间介电常数的不同使反射波发生变化,反射系数与介电常数的关系如式(1)所示。当电磁波从高介电常数的介质层射向低介电常数的介质层时,反射系数为正数,反射相位与入射相位相同,在入射位置呈现为波谷,显示白色;反之,反射系数为负数,反射相位与入射相位相反,在入射位置呈现为波峰,显示黑色,因此脱空病害的双曲线表现为黑白相间的模式,如图 4 所示。本文通过实地取芯验证了上述成像特征的准确性。

$$R = \frac{\sqrt{\alpha_1} - \sqrt{\alpha_2}}{\sqrt{\alpha_1} + \sqrt{\alpha_2}}, \tag{1}$$

式中: α_1, α_2 分别表示相邻界面的介电常数。




图 4 脱空病害成像特征
Fig. 4 Imaging features of cavity disease

在明确脱空病害的成像特征后使用 LabelImg 软件对 GPR B-SCAN 图中的脱空病害进行专家级别的精确标注,病害区域都被一个边界框所围绕,并且配有相应的类别标签,软件会将每个病

害的标记框信息全部保存在txt文本中,如图5所示。其中一行的五个数值对应一个标记框的信息,从前到后分别是目标的类别序号、中心点横坐标、中心点纵坐标、标注框的宽和高,真实反应了脱空病害在图像中的位置和大小,且四个位置

信息都是经过归一化处理后得到的数值。本文共标注了2 589张GPR B-SCAN图像并将其用于模型训练,其中脱空实例共计18 264个,在模型训练前将所有图像数据按7:3的比例划分为训练集和验证集。




图5 病害标注过程

Fig. 5 Disease labeling process

2 改进网络模型研究

2.1 网络模型适应性分析

道路脱空病害检测中,不同形状病害的特征差异容易导致模型混淆,且在实际场景中复杂的背景对识别精度有较大影响。由于病害识别精确度依赖于算法模型的泛化能力和适应性,因此,在使用深度学习技术解决实际问题时,熟悉算法底层原理并根据病害特征选择合适模型以及调用函数至关重要。YOLOv5s实时检测模型主要由骨干网络、颈部网络和检测头三部分组成,骨干网络负责提供三个不同采样尺度下的特征图,颈部网络负责融合骨干网络输出的特征图,加强对特征的提取,检测头负责对所有Anchor框分类和回归,并输出模型最终预测结果。训练过程中的每轮迭代都通过CIOU损失函数不断调整模型参数,以最小化损失函数,从而优化模型性能^[13]。针对道路地下脱空病害的实际呈现特征,为提高

识别准确率,本文在YOLOv5s模型的基础上做出如下改进:

首先,为解决普通卷积只能通过固定位置的卷积核提取特征图上的信息,导致其在面对脱空病害这种形态多变的目标时适应性较弱,存在关键特征提取效果较差的问题^[14],本文通过分析病害特征,提出采用可变形卷积(DCNv2)替换骨干网络中C3模块的普通卷积,允许卷积核在空间上根据输入特征图的内容自适应调整采样位置,以期提高对形态多变目标的关键特征提取能力;其次,道路地下环境的复杂性导致GPR B-SCAN图像中干扰因素较多,相较原网络模型中的CIOU损失函数,Focal-EIOU损失函数可通过优化惩罚项更准确地衡量预测框和真实框之间的相似性,并提升高质量锚框对模型收敛的贡献度;最后,为了减少无关背景信息对模型提取目标特征造成的干扰,在三个检测头之前加入SimAM注意力机制,从而提升模型对目标特征的判别能力。改进后的网络模型如图6所示。

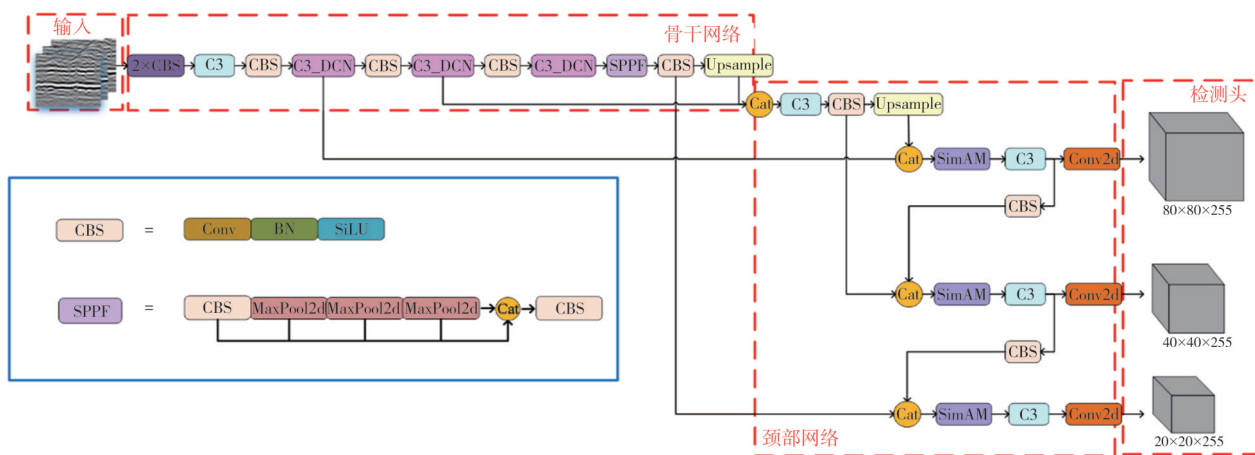


图6 DFES-YOLOv5s网络模型

Fig. 6 DFES-YOLOv5s network model

2.2 可变形卷积模块设计

为了使模型能够更好地适应脱空病害形态多变的特点,加强对局部特征的提取,提高检测精度,使用DCNv2替换C3模块中的普通卷积,即C3_DCN模块。DCNv2通过在卷积运算之前添加一个额外的卷积模块,动态学习每个卷积采样点的偏移量,并通过插值操作调整卷积核的形状,从而灵活适应目标的形态变化,如图7所示。这种动态适应机制使得模型能够根据输入特征图的内容微调卷积核,帮助模型有效提取形态多变目标的边缘、纹理等细节信息,准确定位目标关键区域。相比于普通卷积模块,C3_DCN模块在提取形态多变目标的局部特征和提升检测精度方面具有显著优势。




图7 DCNv2结构

Fig. 7 DCNv2 structure

DCNv2中的权重模块使卷积分支在预测采样点偏移量的同时也预测了每个采样点的权重,将质量差的采样点权重置为0,减少了一些不必要的计算,提高了网络对重要特征的关注度。DCNv2的计算公式为

$$f(p_0) = \sum_{p_n \in R} \omega(p_n) \cdot x(p_0 + p_n + \Delta p_n) \cdot \Delta m_k, \quad (2)$$

式中: $f(p_0)$ 为输出特征图特定位置的值; Δp_n 为学习到的位置偏移量,用于调整卷积核的采样点位置; p_0 为卷积核中心点的位置; p_n 为卷积核中每个采样点与中心点的相对位置; $x(p_0 + p_n + \Delta p_n)$ 表示输入特征图 $p_0 + p_n + \Delta p_n$ 位置的值; $\omega(p_n)$ 表示位置 p_n 处的卷积核权重; Δm_k 表示学习到的特征权重,用于对采样点的特征值进行加

权,取值范围在(0, 1)之间。

2.3 Focal-EIOU 损失函数分析

EIOU损失函数包括:重叠损失、中心距离损失和宽高损失三部分,如式(3)所示,其中 w^c 和 h^c 分别表示覆盖预测框和真实框最小外接框的宽度和高度^[15]。式(3)的前两部分延续CIOU损失函数的方法最小化预测框和真实框之间的重叠区域以及中心点之间的距离,最后一部分在CIOU损失函数的基础上将纵横比拆开,分别计算宽度和高度的差异,这样能够更准确地衡量两个边界框之间的相似性,尤其是在目标形状和大小多变的情况下,能够加快模型的收敛速度。

$$L_{EIOU} = 1 - IOU + \frac{\rho^2(b, b^{gt})}{(w^c)^2 + (h^c)^2} + \frac{\rho^2(w, w^{gt})}{(w^c)^2} + \frac{\rho^2(h, h^{gt})}{(h^c)^2}. \quad (3)$$

此外,本实验使用GPR在山西高速公路上采集的百公里图像数据,相比从受控环境仿真得到的图像数据,真实的地下环境包含更多干扰噪声,导致脱空病害辨识度低,模型难以有效识别。

Focal Loss损失函数旨在解决目标检测中的正负样本不平衡的问题,它基于交叉熵损失并加入了调节因子(如式(4)所示)。 α_t 用于平衡正负样本的影响, γ 控制易分类样本的权重,使得模型更专注于难分类样本的训练。此思想同样可有效解决脱空病害检测任务中因背景干扰噪声过多导致的正负样本难以分辨的问题。

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t). \quad (4)$$

本文基于Focal Loss赋予难分类样本更高权重来解决类别不平衡问题的思想,在EIOU损失函数的基础上引入了类似的调节机制,不同的是Focal-EIOU赋予了高质量样本更高的权重,抑制了与真实目标框重叠比例较少的预测框(异常值)对模型回归的贡献度。在提高模型定位精度的同时,解决了类别不平衡的问题,公式为

$$L_{Focal-EIOU} = IOU^\sigma L_{EIOU}, \quad (5)$$

式中: σ 表示控制异常值抑制程度的参数; L_{EIOU} 表示标准的EIOU损失值。融入 IOU^σ 项使模型更专注高质量样本。

2.4 SimAM注意力机制

在道路地下脱空病害检测场景中,部分背景信

息与待检测目标具有相似的特征,给脱空病害的准确识别带来了极大挑战。因此,为提升模型对目标特征的敏感度,抑制无关信息的干扰,本文在模型的三个检测头之前加入了SimAM注意力机制,以增强模型在复杂背景下的检测精度和鲁棒性。

SimAM是一种简洁高效的注意力机制,它结合了通道信息和空间信息,通过三维权重机制同时在通道维度和空间维度上学习权重,从而保证了每个神经元都会被分配一个唯一的权重,如图8所示。




图8 SimAM注意力机制

Fig. 8 SimAM attention mechanism

在不增加额外参数的前提下,SimAM能够学习到更具辨识力的神经元,使模型能够专注于特征图中的关键信息,提升了模型的目标特征表示和判别的能力。SimAM为每个神经元定义了能量函数,具体计算为

$$e_i^* = \frac{4(\hat{\sigma}^2 + \partial)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\partial}, \quad (6)$$

式中: ∂ 表示正则化系数; t 表示目标神经元; $\hat{\mu}$ 表示通道上神经元的平均值,计算公式如式(7)所示; $\hat{\sigma}^2$ 表示所有神经元的方差,计算公式如式(8)

所示。 e_i^* 越小表示目标神经元 t 与其他神经元的区别越大,重要性越高。

$$\hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i, \quad (7)$$

$$\hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu})^2, \quad (8)$$

式中: M 表示神经元的个数; x_i 表示其他神经元的输入特征。

3 实验结果和讨论

3.1 实验环境和训练参数

本文实验运行环境为Ubuntu 20.04,使用Intel Xeon w9-3495X CPU处理器和NVIDIA RTX A6000 GPU显卡,并在Python 3.7和PyTorch 1.13.1环境中实现,使用CUDA 11.7对GPU加速。训练过程中的具体参数如表1所示。

表1 模型的训练参数

Tab. 1 Training parameters for the model

参数	值
输入图片大小/像素	640×640
初始学习率	0.01
Batch Size	16
Epoch/轮	150
优化器	SGD
权重衰减	0.0005

3.2 对比实验

为了验证DFES-YOLOv5s模型的性能优势,将其与SSD、Faster-RCNN YOLOv5n、YOLOv7-tiny、YOLOv7、YOLOv9、YOLOv11和YOLOv5s八种主流的目标检测模型进行比较,实验结果如表2所示。

表2 9种模型对比实验

Tab. 2 Comparative experiments with nine models

模型	AP0.5/%	P/%	R/%	F1	参数量	FLOPs
SSD	74.5	70.3	79.6	0.74	2.374×10^7	3.496×10^{10}
Faster-RCNN	60.9	68.6	64.2	0.66	1.1954×10^8	7.246×10^{10}
YOLOv5n	79.1	70.6	74.3	0.72	1.760×10^6	4.100×10^9
YOLOv7-tiny	73.6	71.5	67.4	0.69	6.010×10^6	1.300×10^{10}
YOLOv7	79.6	73.5	73.3	0.73	3.648×10^7	1.032×10^{11}
YOLOv9	78.9	72.8	74.8	0.74	7.028×10^7	3.134×10^{11}
YOLOv11	77.0	71.8	71.1	0.71	2.580×10^6	6.300×10^9
YOLOv5s	83.2	74.5	77.2	0.75	7.020×10^6	1.580×10^{10}
DFES-YOLOv5s	88.5	84.2	84.2	0.82	7.200×10^6	1.370×10^{10}

经过对比发现相较于表中其他目标检测模型,YOLOv5s在保持较高检测精度的同时具有较小的参数量和较低的计算复杂度。此外,相较于

最新的YOLOv11模型,YOLOv5s在道路地下脱空病害检测场景中具有更好的表现效果,因此,本文选择YOLOv5s作为基础模型。在此基础上

改进的DFES-YOLOv5s模型虽然参数量有所增加,但因为DCNv2的引入减少了一些不必要的计算,所以整体的FLOPs并没有提高。实验结果表明,DFES-YOLOv5s模型在保持轻量化的同时其平均精确度、准确率、召回率都达到了最高,分别为88.5%,84.2%和84.2%。

为了进一步验证DFES-YOLOv5s模型在脱空病害检测方面的优势,对比了其于YOLOv5s模型对相同图像的部分检测结果。在背景干净但脱空病害形态多样的图像中,YOLOv5s模型会出现漏检的情况,而DFES-YOLOv5s能够准确识别出不同形态的脱空病害,如图9所示,其中红色矩形框为改进前模型未能识别出的脱空病害的位

置。在背景杂乱且存在与目标特征相似信息的图像中,DFES-YOLOv5s模型表现出更强的抗干扰能力,有效排除了无关信息的干扰,并准确检测出了脱空病害的位置,如图10所示,其中红色矩形框同样为改进前模型未识别出的脱空病害的位置。当小尺寸脱空病害密集出现时,虽然两个模型都能够识别出全部目标,但由于改进后的模型在目标定位上的精度更高,导致YOLOv5s模型的预测框置信度普遍低于本文改进后的DFES-YOLOv5s模型,如图11所示。这表明DFES-YOLOv5s模型不仅具有更高的识别准确率,还显著降低了模型的漏检率,验证了其在道路地下脱空病害检测任务中的有效性与高鲁棒性。




图9 形态多变目标的脱空检测

Fig. 9 Cavity detection for morphologically varying targets




图10 复杂背景下的脱空检测

Fig. 10 Cavity detection in complex backgrounds

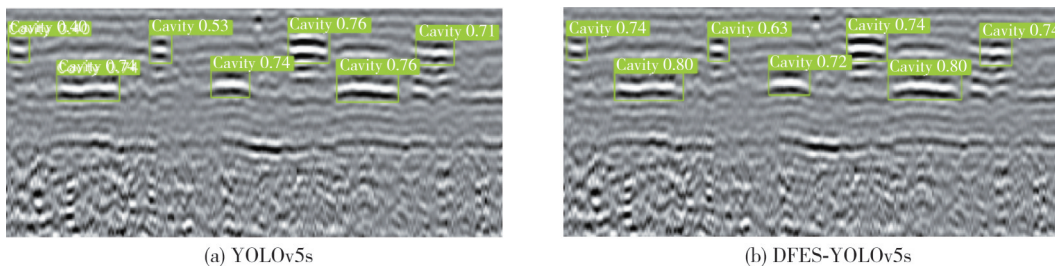


图11 小尺寸目标的脱空检测

Fig. 11 Cavity detection for small size targets

3.3 消融实验

为了观察不同改进模块对道路地下脱空病害检测性能的影响,针对DFES-YOLOv5s模型的关键组件进行了一系列消融实验,如表3所示。将YOLOv5s模型与改进模型进行对比来更直观地

观察改进方法的有效性以及不同组合之间的差异。

从表3中可以明显看出,仅使用Focal Loss作为模型的损失函数,虽然解决了类别不平衡的问题,提高了模型的检测精度,但由于定位精度较低,导致模型的漏检率增大,在与EIOU损失函数相结合

后更准确地衡量了预测框和真实框之间的相似性,因此,模型整体性能得到了提高;在此基础上设计新的C3_DCN模块代替了YOLOv5s骨干网络中原有的C3模块,加强了模型对形态多变目标的适应性,进一步提升了模型的性能;最后,在检测头之前加

入SimAM注意力机制,提升了模型的目标特征表示和判别的能力。相较于YOLOv5s,本文改进模型的AP、P和R分别提高了5.3百分点,9.7百分点和7.0百分点,再次证明了DFES-YOLOv5s模型在脱空病害目标检测方面的高效性。

表3 消融实验

Tab.3 Ablation experiment

Num	CIOU	Focal	Focal-EIOU	C3_DCN	SimAM	AP0.5/%	P/%	R/%	F1
1	✓					83.2	74.5	77.2	0.75
2		✓				83.4	77.1	76.2	0.76
3			✓			83.6	75.9	77.7	0.77
4			✓	✓		88.5	82.1	82.2	0.82
5			✓	✓	✓	88.5	84.2	84.2	0.84

4 结论

针对道路地下脱空病害的目标检测任务,本文提出了DFES-YOLOv5s模型用于检测GPR B-SCAN图像中的脱空病害。该方法首先利用GPR无损探测技术在山西高速公路上采集了百公里的B-SCAN图像数据作为模型训练所需的数据集,其次为了提高模型对形态多变目标的识别能力,设计新的C3_DCN模块替换YOLOv5s骨干网络中的原C3模块,然后使用Focal-EIOU作为模型训练的损失函数,在加快了模型收敛速度的同时解决了正负样本难以分辨的问题,最后在三个检测头前加入SimAM注意力机制,加强了模型对重要特征的关注。结果表明,本文提出的DFES-YOLOv5s智能检测模型具有高效性,也为道路病害预知和维护提供了数字化、智能化手段。

参考文献:

- [1] 赵钉毅. 基于深度学习的探地雷达道路病害诊断与分析研究[D]. 深圳: 深圳大学, 2022.
- [2] ZHAO K, HAN Q, ZHANG C B, et al. Deep hough transform for semantic line detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 4793-4806.
- [3] 苏勇刚, 高茂庭. 基于深度学习的SIFT图像检索算法[J]. 计算机系统应用, 2020, 29(9): 164-170.
SU Yonggang, GAO Maoting. SIFT image retrieval algorithm based on deep learning [J]. Computer System Applications, 2020, 29 (9) : 164-170. (in Chinese)
- [4] 徐启文, 唐振民, 姚亚洲. 基于改进SURF算法的图像拼接研究[J]. 南京理工大学学报, 2021, 45(2): 171-178.
XU Qiwen, TANG Zhenmin, YAO Yazhou. Research

on image mosaic based on improved SURF algorithm [J]. Journal of Nanjing University of Science and Technology, 2021, 45(2): 171-178.

- [5] KANG M S, KIM N, IM S B, et al. 3D GPR image-based UcNet for enhancing underground cavity detectability[J]. Remote Sensing, 2019, 11(21): 2545.
- [6] 江路路, 尹轶, 孟姿含, 等. 基于YOLO v5的探地雷达地下空洞与管线图像自动识别技术[J]. 国防交通工程与技术, 2024, 22(5): 7-11.
JIANG Lulu, YIN Yi, MENG Zihan, et al. Automatic recognition technology of underground cavities and pipelines in ground penetrating radar images based on YOLO v5 [J]. Traffic Engineering and Technology for National Defence, 2024, 22 (5) : 7-11. (in Chinese)
- [7] LI Y H, ZHAO Z X, LUO Y F, et al. Real-time pattern-recognition of GPR images with YOLO v3 implemented by tensorflow [J]. Sensors (Basel), 2020, 20(22): 6476.
- [8] QIU Z, ZHAO Z X, CHEN S J, et al. Application of an improved YOLOv5 algorithm in real-time detection of foreign objects by ground penetrating radar [J]. Remote Sensing, 2022, 14(8): 1895.
- [9] LUO T X H, ZHOU Y F, ZHENG Q Z, et al. Lightweight deep learning model for identifying tunnel lining defects based on GPR data [J]. Automation in Construction, 2024, 165: 105506.
- [10] 周中, 周诗荣, 李世帅, 等. 基于改进YOLOv7的隧道衬砌内部缺陷智能识别[J/OL]. 铁道学报(2024-07-23) [2024-11-20]. <http://kns.cnki.net/kcms/detail/11.2104.U.20240722.1543.002.html>.
ZHOU Zhong, ZHOU Shirong, LI Shishuai, et al. Intelligent identification of inner defects in tunnel lining based on improved YOLOv7 [J/OL]. Journal of the China Railway Society (2024- 07-23) [2024-11-20].

- <http://kns.cnki.net/kcms/detail/11.2104.U.20240722.1543.002.html>. (in Chinese)
- [11] OMWENGA M M, WU D L, LIANG Y, et al. Cognitive GPR for subsurface object detection based on deep reinforcement learning [J]. IEEE Internet of Things Journal, 2021, 8(14): 11594-11606.
- [12] HU H B, FANG H Y, WANG N N, et al. Defects identification and location of underground space for ground penetrating radar based on deep learning [J]. Tunnelling and Underground Space Technology Incorporating Trenchless Technology Research, 2023, 140: 105278.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [DB/OL]. (2016-5-19)[2024-11-20]. <https://arxiv.org/abs/1506.02640>.
- [14] 梁佳杰, 徐慧英, 朱信忠, 等. 基于改进的YOLOv8n海洋动物目标检测算法:DPSC-YOLO [J]. 计算机工程与科学, 2025, 47(4): 695-705.
- LIANG Jiajie, XU Huiying, ZHU Xinzhong, et al. An improved marine animal object detection algorithm based on YOLOv8n: DPSC-YOLO[J]. Computer Engineering & Science, 2025, 47(4): 695-705. (in Chinese)
- [15] 谢国波, 林松泽, 林志毅, 等. 基于改进YOLOv7-tiny的道路病害检测算法[J]. 图学学报, 2024, 45(5): 987-997.
- XIE Guobo, LIN Songze, LIN Zhiyi, et al. Road defect detection algorithm based on improved YOLOv7-tiny[J]. Journal of Graphics, 2024, 45(5): 987-997. (in Chinese)