

基于 YOLO 的板式橡胶支座多表观病害检测方法对比研究

鲁德文, 李 晰*

(青岛理工大学 土木工程学院, 青岛 266525)

摘要: 为了提升板式橡胶支座的病害检测精度, 采用 YOLO (You Only Look Once) 系列中的 YOLOv3、YOLOv4、YOLOR 这 3 种算法针对板式橡胶支座的多种表观病害进行检测并对其检测性能进行对比研究。建立由 6787 张图片组成的支座病害 (BD) 数据集, 涵盖开裂、锈蚀、脱空、龟裂、垃圾、外鼓和剪切变形 7 种病害。采用 YOLOv3、YOLOv4、YOLOR 算法基于 BD 数据集进行训练, 并给出了与之对应的 3 种检测方法。基于此, 对 3 种检测方法进行检测性能对比实验。研究结果表明: 针对板式橡胶支座多表观病害, YOLOv3 与 YOLOv4 检测性能接近, 而 YOLOR 相较 YOLOv3 和 YOLOv4 整体召回率 (R) 和平均精度均值 (P_{mAP}) 提升显著, 分别提升了 59.7% 和 92.7%, 针对各类病害检测性能也存在不同程度的提升。因此, 基于 YOLOR 的检测方法更适用于板式橡胶支座多种表观病害的检测。

关键词: 板式橡胶支座; YOLO; 表观病害; 病害检测

中图分类号: U446.2 **文献标志码:** A **文章编号:** 1673-4602(2025)03-0001-08

Comparative research on the detection methods of multi-apparent defects in laminated bearings based on YOLO

LU Dewen, LI Xi*

(School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: To enhance the detection accuracy of apparent defects in laminated bearings, three algorithms, YOLOv3, YOLOv4 and YOLOR from the YOLO (You Only Look Once) series, are used to detect the various apparent defects in laminated bearings, and comparative research is conducted to evaluate their respective detection performance. Initially, a bearing defect dataset (BD dataset) comprising 6787 images is established, including seven types of defects, namely crack, bulging, rust, void, crazing, shear deformation and garbage. Subsequently, the YOLOv3, YOLOv4 and YOLOR are employed for training based on the BD dataset, and three corresponding detection methods are provided. Following this, a comparative experimental analysis of the detection performance of the three detection methods is conducted. The results indicate that for the multiple apparent defects in laminated bearings, the detection performance of YOLOv3 is close to that of YOLOv4, while compared with YOLOv3 and YOLOv4, YOLOR exhibits a significant increase of 59.7% in overall R and

收稿日期: 2024-01-08

基金项目: 国家重点研发计划 (2022YFC3801104)

作者简介: 鲁德文 (1998—), 男, 山东济南人。硕士, 研究方向为人工智能在桥梁结构中的应用。E-mail: 13409097057@163.com。

* 通信作者: 李 晰 (1984—), 男, 山东栖霞人。博士, 副教授, 主要从事人工智能在桥梁结构中的应用等方面的研究。

E-mail: xi.li@qut.edu.cn.

92.7% in P_{mA} . Additionally, varying degrees of improvement in the detection performance for different types of defects are observed. Therefore, the detection method based on YOLOR is more suitable for the detection of multiple apparent defects in laminated bearings.

Key words: laminated bearing; YOLO; apparent defect; defects detection

支座受橡胶老化、车辆超载等多重因素的影响,会不可避免地出现开裂、脱空、剪切变形等病害^[1],进而影响桥梁结构的安全性和耐久性,现阶段,随着桥梁数量递增,桥梁支座的检测任务也日益繁重,从国家多次修订相关规范中针对支座检测的内容可以看出支座检测逐渐受到重视。随着计算机视觉技术和人工智能^[2]的飞速发展,基于深度学习^[3]的目标检测技术在桥梁病害检测的应用成为研究热点。目标检测是计算机视觉领域关注的核心问题之一,其任务是找出图像中所有感兴趣的目标并确定它们的类别和位置,这与桥梁病害检测任务高度匹配。目标检测可分为双阶段和单阶段2种检测方法,而单阶段的YOLO系列算法以其检测速度快、检测精度高等特点被广泛地应用于桥梁智能化检测。

在桥梁智能化检测领域,多数学者将YOLO系列应用于针对混凝土桥、钢桥的病害检测技术中。混凝土桥方面,ZHANG等^[4]通过改良YOLOv3的小目标检测能力,可对混凝土表观的裂缝病害实现高精度的识别。邹俊志等^[5]基于改进后的YOLOv3检测模型可检测桥梁的露筋、剥落和渗水3种病害。钢桥方面,HAN等^[6]基于YOLOv3实现高精度检测钢桥裂缝、锈蚀等病害。可以看出,基于YOLOv3的检测方法得到了广泛的研究与发展。随着YOLO系列的发展,谌婷婷等^[7]基于YOLOv4对混凝土裂缝进行高精度检测。YU等^[8]建立更轻量化的YOLOv4-FPM检测模型可用于实时的裂缝检测。基于YOLOv4的检测方法同样得以发展。上述研究证明了YOLOv3和YOLOv4在桥梁病害检测领域的适用性。

而在现阶段支座的智能化检测技术中,由于位置特殊,不易观测等原因,有关支座病害智能检测技术的研究相对较少。GARCIA-SANCHEZ等^[9]基于传感器所采集的支座位移数据,并结合“主成分分析”的无监督学习方法,最终建立了考虑温度、环境等因素影响的支座位移基线模型,并利用该模型监测支座位移是否超过基线,进而判断支座是否发生损坏。陈红霞等^[10]利用高斯函数和BP神经网络等技术对支座的损伤位置和程度进行了识别。但此类支座检测方法不仅需要长时间的采集数据且检测结果多为二分类。崔弥达^[11]利用图像反转等数据增强技术构建并训练了VGG的支座病害检测模型,该模型可以将支座照片分为正常、开裂、剪切变形。在随后的研究中,CUI等^[12]还利用尺度不变特征变化技术(Scale-Invariant Feature Transform, SIFT)和支持向量机分类器技术(Support Vector Machine, SVM)开发了全新的图像数据集,并结合迁移学习算法给出了基于AlexNet、VGG-11以及ResNet-18的支座病害检测模型,可以更准确地对支座病害照片进行分类,基于此类深度学习和图像处理技术的检测方法^[13-15]开始得到普及与研究。综上所述,现有支座检测方法可检测的病害种类较少不满足规范的相关要求,并且多数支座检测模型都无法直观展示病害位置、种类等信息,所以目前的支座智能化检测在病害识别种类、检测精度等方面都有待进一步提升。

从上述针对支座检测的研究可以看出,目前YOLO系列没有应用于支座病害检测且不同YOLO算法之间的横向对比研究较少。因此,本文基于YOLO系列,采用YOLOv3^[16]、YOLOv4^[17]以及YOLOR^[18]针对板式橡胶支座的多种表观病害进行训练,提出3种检测方法,并从准确率、召回率、所有病害的平均精度均值等性能指标进行对比分析,为检测板式橡胶支座的多种表观病害提供技术支持。

1 板式橡胶支座病害数据集

1.1 病害划分依据

板式橡胶支座由多层天然橡胶或氯丁橡胶与薄钢板镶嵌、粘合、硫化而成,天然橡胶和氯丁橡胶容易受氧化、高温等外界因素的影响发生老化,进而出现开裂、龟裂等病害。同时,支座不仅需要承受桥梁上部结构所传递下来的荷载,还需确保桥梁上部结构能满足相应的变形,这种受力特点使得支座还容易出现外鼓、脱空、剪切变形等病害。此外,由于支座的上下座板多为钢材,故容易发生锈蚀病害。这些病害会影响支座的正常功能,加速桥梁的整体破坏。国家相关桥梁检测规范^[19]多次对于支座的检测内容进行更新与

补充,同时桥梁养护规范^[20]不仅对于支座本身,还对支座所处的服役环境等因素提出了相关检测要求。因此,本文基于规范中的检测要求,并结合计算机视觉的特点,对部分条目进行了重分类和再补充。最终划分 7 种支座表观病害,分别为:开裂(Crack)、锈蚀(Rust)、脱空(Void)、龟裂(Crazing)、垃圾(Garbage)、外鼓(Bulging)、剪切变形(Shear Deformation),如图 1 所示。




图 1 划分病害示意

1.2 数据集特征分析

依据 1.1 节的病害划分,构建了板式橡胶支座的表观病害(Bearing Defects, BD)数据集并使用 VOTT 软件进行标注,标记原则为:①用矩形框对病害进行标注;②使标注框贴近病害边缘,减少背景;③使同类病害的标记框尺寸差异较小。标注完成后由专业的巡检人员进行校核以保证标注病害的准确性,标注界面和标注示例如图 2 所示。

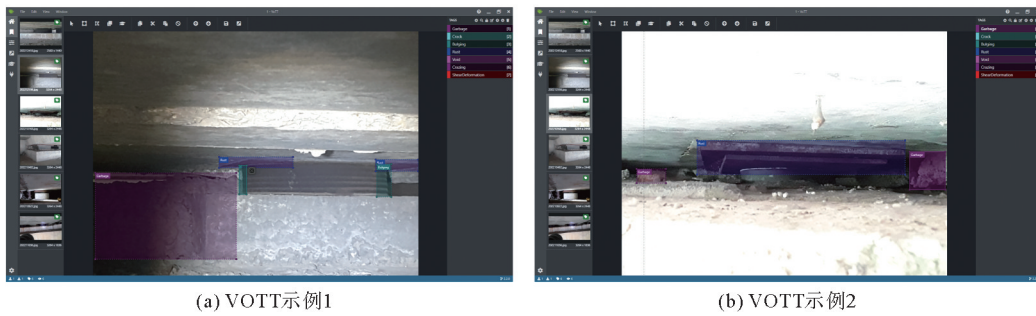


图 2 VOTT 标注支座病害

BD 数据集共由 6787 张照片组成,其中 5442 张用作训练集、1345 张用作验证集。为了使 BD 数据集有更好的适用性,没有对拍摄设备、拍摄环境以及分辨率大小等因素做出限制。从图 3(a)中可看出数据集中照片的分辨率涵盖 640×360 到 5184×3888 的范围,这可使 BD 数据集有更好的代表性,从而进一步增强检测模型的鲁棒性。BD 数据集共包含 18 063 个标注框。

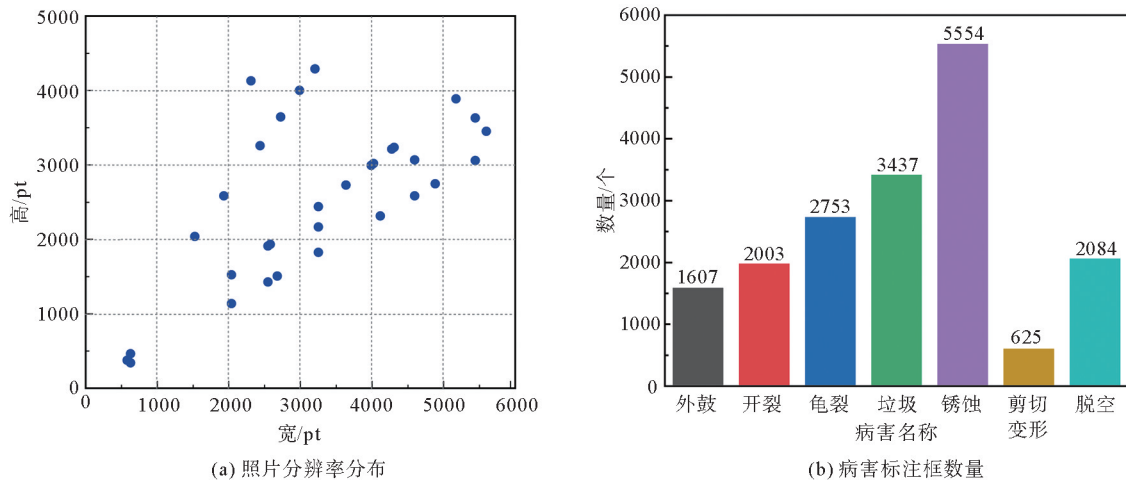


图 3 BD 数据集信息

各病害标注框的数量如图 3(b)所示,其中锈蚀和垃圾的标注框数量最多,分别为 5554 个和 3437 个标注框,其次为龟裂、脱空、开裂和外鼓,均在 2000 个标注框左右,而剪切变形的标注框数量最少,只有 625 个。这是因为在支座的日常检测中,对于垃圾与锈蚀这 2 种病害,由于对支座性能影响较小,不进行紧急处理,故最为常见。而对于龟裂、开裂、外鼓和脱空等病害只在支座橡胶发生老化时才出现,故相对于垃圾和锈蚀数量较少。此外,对于剪切变形的情况,由于在检测过程中一旦发现支座出现严重的剪切变形,就会立即进行更换,因此此类病害的照片不易采集,导致标注框的数量最少。

2 检测方法概述及性能指标

2.1 YOLO 系列概述

YOLOv3^[16]是 YOLO 系列中里程碑式的算法,后续 YOLO 的发展都是基于此展开研究与改进的。其整体结构可分为输入端(Input)、主干网络(Backbone)、颈部结构(Neck)和检测端(Head),如图 4 所示。输入端将输入的图片进行压缩并划分网格;主干网络采用 Darknet53 网络来提取输入图片的特征并形成多层特征图;颈部结构采用转置卷积等技术将来自主干网络不同尺度的特征图进行融合和处理,以便在不同尺度上检测目标;检测端负责在特征图上进行检测。YOLOv3 的检测端由 3 个检测头组成,每个检测头针对不同尺寸的特征图进行检测。YOLOv3 提出的此类神经网络结构的思路在 YOLO 系列的后续发展中也一直得以沿用,并不断对结构中的各个部分进行升级与改动。




图 4 YOLOv3 神经网络结构

YOLOv4^[17]的主要改进体现在主干网络中,用 CSPDarknet53 作为新的主干网络结构。CSP(Cross Stage Partial)连接是通过部分连接的方式改善了特征的传递,有助于减少信息丢失从而更好地传递特征。YOLOv5^[18]将主干网络替换成 UNMT(Unified Network for Multiple Tasks)新型网络结构。该网络结构受人类总结经验进而处理已知或未知信息这种学习方式的启发,同时编码显性知识和隐性知识,并执行了核空间对齐(kernel space alignment)、预测细化(prediction refinement)等算法,在检测端,检测头由 3 个增至 4 个,锚框数量由 9 个增至 12 个,因此可以更好检测不同尺寸的多种目标,有效地提升了进行多任务检测的性能。

YOLO 系列训练是通过前向传播和反向传播不断地优化综合损失函数中的相关参数来更好地定位目标位置、确定物体类别以及确定锚框中是否包含目标。综合损失函数可由定位损失(Localization Loss, L_{Loc})、分类损失(Classification Loss, L_{Cls})和置信度损失(Confidence Loss, L_{Conf})组成。其基本原理如下:

L_{Loc} 是衡量预测框的位置和大小与真实框之间的差异,若预测框的 4 个坐标为 (x, y, w, h) , 真实框的 4 个坐标为 $(x_{ture}, y_{ture}, w_{ture}, h_{ture})$, 计算方法如式(1)所示:

$$L_{Loc} = \lambda_{Loc} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - x_{iture})^2 + (y_i - y_{iture})^2 + (\sqrt{w_i} - \sqrt{w_{iture}})^2 + (\sqrt{h_i} - \sqrt{h_{iture}})^2] \quad (1)$$

式中: λ_{Loc} 为平衡定位损失和其他损失的超参数; S^2 为网格单元数量; B 为每个单元网格的预测框数量; 1_{ij}^{obj} 是一个指示函数,表示第 i 个网格单元中第 j 个锚框是否包含对象。

L_{Cls} 是衡量模型对物体类型的预测准确性,使用交叉熵损失函数计算,假设模型输出了 C 个类别概率,实际类别为 p_{ture} ,其计算方法按式(2)所示:

$$L_{Cls} = \lambda_{Cls} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \sum_{c=0}^C (p_{ij}^c - p_{iture}^c)^2 \quad (2)$$

式中: λ_{Cls} 为平衡分类损失和其他损失的超参数; p_{ij}^c 为第 i 个网格单元中第 j 个锚框对类别 c 的预测概率。

L_{Conf} 为衡量模型对锚框是否包含物体的预测准确性,计算方法如式(3)所示:

$$L_{Conf} = \lambda_{Conf} \sum_{i=0}^{S^2} \sum_{j=0}^B (1_{ij}^{obj} (C_{ij} - 1_{ij}^{obj})^2 + 1_{ij}^{noobj} (C_{ij} - 1_{ij}^{obj})^2) \quad (3)$$

式中: λ_{Conf} 为平衡置信度损失和其他损失的超参数; 1_{ij}^{noobj} 为指示函数,表示第 i 个网格单元中第 j 个锚框是否不包含目标, C_{ij} 为置信框坐标。

2.2 性能评价指标

本文选择目标检测中常用的评价指标来进行结果分析,采用的评价指标有召回率(Recall, R)、准确率(Precision, P)、单类病害精度均值(Average Precision, P_A)、所有病害的平均精度均值(mean Average Precision, P_{mA})和检测速度(Frame Per Second, S_{FP})等。

首先需要引入交并比(Intersection over Union, IoU)的概念,依照公式(4)计算:

$$I_{IoU}(A, B) = \frac{\text{Intersection_area}}{\text{Union_area}} = \frac{A \cap B}{A \cup B} \quad (4)$$

式中: $A \cap B$ 和 $A \cup B$ 的计算方法分别如图5所示; A 框为人工标注的真实框(Ground Truth Box); B 框为模型进行计算输出的预测框(Prediction Box)。




图5 IoU 示意

IoU 的值越大,说明预测框与真实框越接近,检测效果越好;IoU 的值越小,说明预测框与真实框越远,检测效果越差。按照病害检测的任务要求,本文将 IoU 的阈值设置为 0.25。当 IoU 大于 0.25 时,将此预测框归为真正例(True Positives, P_T);当 IoU 小于 0.25 时,将此预测框归为假正例(False Positives, P_F);而没有被检测到的预测框,被认定为假反例(False Negatives, N_F)。

召回率 R 用于描述正确检测到的病害数目占所有需要被检测到的病害数目的比例。准确率 P 用于描述正确检测到的病害数目占所有检测到的病害数目的比例。可按式(5)(6)计算:

$$P = \frac{P_T}{P_T + P_F} \quad (5)$$

$$R = \frac{P_T}{P_T + N_F} \quad (6)$$

P_A 用于描述检测模型针对某一种病害的检测性能,当检测病害数量 ≥ 2 时,判定检测模型的整体性能应用 P_{mA} ,其数值越高性能越好。可按式(7)(8)计算:

$$P_A = \int_0^1 P(R) dR \quad (7)$$

$$P_{mA} = \frac{1}{n} \sum_{i=1}^n P_{Ai} \quad (8)$$

式中: n 为病害的类别数量。

模型的检测速度用每秒帧率 S_{FP} 进行判定,即模型每秒可以处理的图像数量。 S_{FP} 按式(9)(10)计算:

$$S_{FP} = \frac{1000}{T_{total}} \quad (9)$$

$$T_{total} = T_{inference} + T_{NMS} \quad (10)$$

式中: T_{total} 为总时间,ms; $T_{inference}$ 为单张图片进行推理的时间,ms; T_{NMS} 为单张图片进行非极大值抑制处理的时间,ms。

3 检测方法对比实验

3.1 超参数设置

使用 AMD Ryzen™9 5900X 处理器、GeForce RTX™ 3080Ti-12G 显卡和 32G 内存的电脑,通过 Anaconda 安装训练所需的 Pytouch1.7.0、Python 3.8.11、CUDA 11.0、cuDNN 8.4.0 等配套环境,并用 Tensorboard 实时查看训练过程。同时采用 SGD(Stochastic Gradient Descent)的优化算法对各参数进行优化,训练轮次设为 300、学习率设为 0.01、动量参数设为 0.937。本文训练 YOLOv3、YOLOv4、YOLOR 这 3 种检测模型。

3.2 检测性能与分析

训练后各检测方法的整体性能如表 1 所示,YOLOv4 相较于 YOLOv3,准确率下降 4%、召回率和平均精度均值提升约 1%,检测速度提升 23.9%。而 YOLOR 相较于 YOLOv3 与 YOLOv4,准确率和检测速度下降约 11.4%和 17.3%,但召回率和平均精度均值提升约 59.7%和 92.7%。上述变化可以看出,基于 YOLOv3 和 YOLOv4 的检测方法由于神经网络框架相对接近导致整体检测性能相似,但 YOLOv4 由于 CSP 的特征传递方式导致检测速度明显优于 YOLOv3。而基于 YOLOR 检测方法由于召回率的提升使平均精度均值显著提高,其整体性能相较于 YOLOv3 和 YOLOv4 明显提升。准确率降低的原因是由于锚框数量的增加更容易被噪点或其他无关目标影响,造成错误。

表 1 整体检测性能

名称	尺寸/pt	准确率	召回率	平均精度均值	检测速度/fps
YOLOv3	608×608	0.699	0.367	0.317	92
YOLOv4	640×640	0.668	0.370	0.318	114
YOLOR	1280×1280	0.619	0.586	0.611	76

注:1 fps=3.048×10⁻¹ m/s。

针对多病害时,由于各病害尺寸、形状等差异较大,导致对于各病害的检测性能不同,各方法的检测性能如表 2 所示。召回率方面,YOLOv4 相较于 YOLOv3,在检测锈蚀、剪切变形等标注框较大的病害时,召回率得到了一定提升(10.2%~24.3%),但在检测开裂、龟裂等细小病害时,召回率降低(9.7%~37.7%)。而 YOLOR 相较于 YOLOv3 和 YOLOv4,检测各病害的召回率都得到了不同程度的提升(17.5%~780.5%)。

结合表 2 可以看出,对于开裂、脱空等细小病害,YOLOv3 和 YOLOv4 的召回率最低,不足 0.1,而 YOLOR 则由于检测端的改进可以更好地检测此类病害,相较于 YOLOv3 和 YOLOv4,对于开裂,提升 419.7%和 780.6%;对于脱空,提升 171.4%和 335.4%。对于龟裂、垃圾等形状尺寸有明显差异的病害,YOLOR 也展示出更全面的检测性,对于龟裂,提升 67.3%和 85.2%;对于垃圾,提升 60.5%和 29.1%。

对于外鼓,提升 53.4% 和 107.7%;对于锈蚀,提升 34.6% 和 22.1%;对于剪切变形,提升 34.8% 和 17.5%。而对于外鼓、锈蚀、剪切变形等特征明显的病害时,YOLOR 的召回率均在 0.8 以上,实现较高的查全率。各方法的检测效果如图 6 所示。可以看出,对于开裂,YOLOv3 和 YOLOv4 几乎无法检测,而 YOLOR 对于特征明显、清晰可见的开裂可以有效检测;对于锈蚀、垃圾、龟裂等病害,YOLOv3 和 YOLOv4 也是存在不同程度的漏识,相比之下 YOLOR 可以做到更全面的检测。因此本文建议,虽然 YOLOv3 和 YOLOv4 在桥梁智能检测领域得到了广泛的应用与研究,但对于板式橡胶支座病害的检测,以 YOLOR 为基础展开研究会取得更加理想的检测效果。

表 2 各病害检测性能

病害	YOLOv3			YOLOv4			YOLOR		
	准确率	召回率	平均精度均值	准确率	召回率	平均精度均值	准确率	召回率	平均精度均值
龟裂	0.688	0.321	0.285	0.686	0.290	0.252	0.627	0.537	0.570
开裂	0.490	0.061	0.040	0.652	0.036	0.025	0.582	0.317	0.419
外鼓	0.559	0.528	0.391	0.580	0.390	0.281	0.598	0.810	0.739
锈蚀	0.874	0.616	0.592	0.828	0.679	0.639	0.792	0.829	0.853
脱空	0.750	0.077	0.060	0.650	0.048	0.042	0.509	0.209	0.362
垃圾	0.647	0.370	0.290	0.559	0.460	0.373	0.546	0.594	0.589
剪切变形	0.881	0.597	0.559	0.718	0.685	0.614	0.678	0.805	0.742

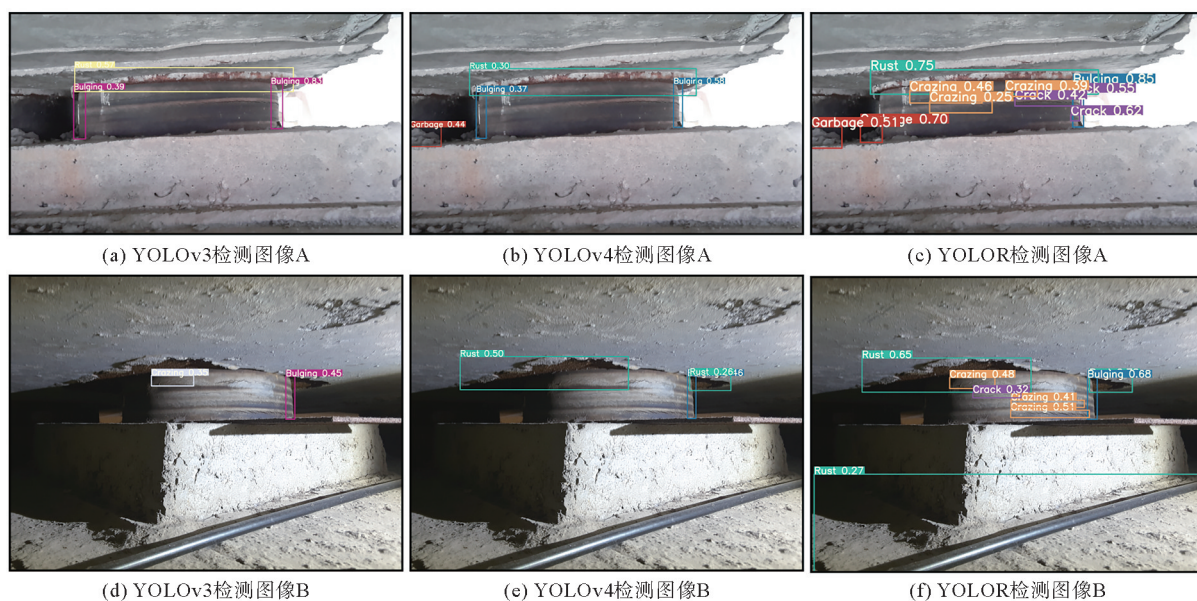


图 6 检测效果

4 结论

建立 6787 张包括开裂、锈蚀、脱空、龟裂、垃圾、外鼓、剪切变形等 7 类病害 BD 数据集,照片分辨率涵盖了 640×360 到 5184×3888 的范围,包含 18 063 个标注框。基于 BD 数据集,采用 YOLOv3、YOLOv4 和 YOLOR 这 3 类算法针对桥梁板式橡胶支座的多种表观病害进行训练,提出 3 种检测方法。从召回率、准确率、精度均值、平均精度均值和检测速度等性能指标对训练后的 3 种检测方法进行性能对比分析。

1) 对于整体检测性能,YOLOv4 相较于 YOLOv3,准确率下降 4%、召回率和平均精度均值分别提升约 1%,检测速度提升 23.9%。YOLOR 相较于 YOLOv3 与 YOLOv4,准确率和检测速度下降约 11.4% 和 17.3%,但召回率和平均精度均值分别提升约 59.7% 和 92.7%。

2) 对于各病害的检测性能。YOLOR 相较于 YOLOv3 和 YOLOv4 在召回率上有着不同程度的提升。开裂提升了 419.7% 和 780.6%, 脱空提升 171.4% 和 335.4%, 龟裂提升 67.3% 和 85.2%, 垃圾提升 60.5% 和 29.1%, 外鼓提升 53.4% 和 107.7%, 锈蚀提升 34.6% 和 22.1%, 剪切变形提升 34.8% 和 17.5%。

参考文献(References):

- [1] 吴宜峰,徐泓,李爱群,等. 桥梁板式橡胶支座运营病害及影响研究综述[J]. 工程抗震与加固改造,2021,43(5):104-113.
WU Yifeng,XU Hong,LI Aiqun,et al. Review on operating disease and effects of bridge plate rubber bearing[J]. Earthquake Resistant Engineering and Retrofitting,2021,43(5):104-113.
- [2] 鲍跃全,李惠. 人工智能时代的土木工程[J]. 土木工程学报,2019,52(5):1-11.
BAO Yuequan,LI Hui. Artificial intelligence for civil engineering[J]. China Civil Engineering Journal,2019,52(5):1-11.
- [3] LECUN Y,BENGIO Y,HINTON G. Deep learning[J]. Nature,2015,521:436-444.
- [4] ZHANG Y,HUANG J,CAI F. On bridge surface crack detection based on an improved YOLOv3 algorithm[J]. IFAC-PapersOnLine,2020,53(2):8205-8210.
- [5] 邹俊志,杨建喜,李昊,等. 复杂背景下基于改进 YOLOv3 算法的桥梁表面病害识别[J]. 铁道科学与工程学报,2021,18(12):3257-3266.
ZOU Junzhi,YANG Jianxi,LI Hao,et al. Bridge apparent damage detection based on the improved YOLOv3 in complex background[J]. Journal of Railway Science and Engineering,2021,18(12):3257-3266.
- [6] HAN Q,ZHAO N,XU J. Recognition and location of steel structure surface corrosion based on unmanned aerial vehicle images[J]. Journal of Civil Structural Health Monitoring,2021,11(5):1375-1392.
- [7] 谌婷婷,魏怡. 基于改进 YOLOv4 的混凝土裂缝检测方法[J]. 激光杂志,2024,45(1):80-85.
SHEN Tingting,WEI Yi. Improved YOLOv4-based concrete crack detection method[J]. Laser Journal,2024,45(1):80-85.
- [8] YU Z,SHEN Y,SHEN C. A real-time detection approach for bridge cracks based on YOLOv4-FPM[J]. Automation in Construction,2021,122:103514.
- [9] GARCIA-SANCHEZ D,FERNANDEZ-NAVAMUEL A,ZAMORA S D,et al. Bearing assessment tool for longitudinal bridge performance[J]. Journal of Civil Structural Health Monitoring,2020,10(5):1023-1036.
- [10] 陈红霞,狄方殿,朱亚洲. 连续梁桥支座损伤识别方法[J]. 土木工程与管理学报,2017,34(4):53-58.
CHEN Hongxia,DI Fangdian,ZHU Yazhou. Bearing damage detection of continuous bridge[J]. Journal of Civil Engineering and Management,2017,34(4):53-58.
- [11] 崔弥达. 基于图像处理的桥梁支座病害自动识别关键技术研究[D]. 南京:东南大学,2018.
CUI Mida. Research of on key techniques of automatic defect identification for bridge bearings based on image processing[D]. Nanjing:Southeast University,2018.
- [12] CUI M,WU G,DANG J,et al. Deep learning-based condition assessment for bridge elastomeric bearings[J]. Journal of Civil Structural Health Monitoring,2022,12(2):245-261.
- [13] MA C F,ZHONG K J,HUANG P M. Application analysis of bridge support safety detection recognition and deep learning image processing technology[C]// International Conference on Transportation and Development,ASCE 2020,2020:1873-1884.
- [14] CHEN Z,FANG H,KE X,et al. A new method to identify bridge bearing damage based on radial basis function neural network[J]. Earthquakes and Structures,2016,11(5):841-859.
- [15] SHI J,DANG J,CUI M,et al. Improvement of damage segmentation based on pixel-level data balance using VGG-Unet[J]. Applied Sciences,2021,11(2):518.
- [16] REDMON J,FARHADI A. YOLOv3: An incremental improvement[M]. San Diego(CA): ArXiv E-prints,2018.
- [17] BOCHKOVSKIY A,WANG C Y,LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[M]. San Diego(CA): ArXiv E-prints,2020.
- [18] WANG C Y,YEH I H,LIAO H Y M. You only learn one representation: Unified network for multiple tasks[M]. San Diego(CA): ArXiv E-prints,2021.
- [19] JTG/T H21—2011,公路桥梁技术状况评定标准[S].
JTG/T H21—2011,Standards for technical condition evaluation of highway bridges[S].
- [20] JTG 5120—2021,公路桥涵养护规范[S].
JTG 5120—2021,Specifications for maintenance of highway bridges and culverts[S].