

基于计算机视觉的钢结构螺栓病害智能检测方法研究

孙 博¹, 王 振^{1,2}, 周学军^{2*}, 李秀领^{1,2}, 冯帅克²

(1. 山东交通学院 交通土建工程学院, 济南 250357; 2. 山东建筑大学 土木工程学院, 济南 250101)

摘 要: 针对钢结构螺栓病害检测中人工目检效率低、漏检和误判率高, 传统深度学习模型检测精度差、抗噪能力弱且计算参数量大等问题, 提出了一种基于改进YOLOv8的螺栓病害检测模型。该模型采用多尺度卷积改进骨干网络, 通过多膨胀率卷积核增强了空间特征提取能力; 通过引入CSPStage和DySample模块优化颈部网络, 强化了多尺度特征融合的效率和质量, 提高了模型在复杂场景下的抗噪能力。数据集获取方面利用DJI Mavic 4 Pro无人机采集了平阴黄河大桥钢桁架节点螺栓图像, 结合CLAHE预处理与数据增强策略提升图像数据质量, 构建了包含锈蚀、松动、缺失三类螺栓病害和正常状态的钢结构螺栓检测数据集。实验结果表明, 相同参数设置下, 改进后的YOLOv8-GDFPN模型在自建数据集上平均准确率均值和准确率分别为83.5%和88.1%, 较YOLOv8模型分别提升了4.9%和4.5%, 模型计算参数量为3.263 M, F_{PS} 值为181.8 帧· s^{-1} , 实现了检测精度与推理效率的平衡, 该模型可为户外复杂场景下的螺栓病害智能检测提供参考。

关键词: 计算机视觉; 螺栓病害智能检测; YOLO算法; 螺栓图像采集; 图像数据集构建; 模型优化; 抗噪能力

中图分类号: TU391, TP391.41

文献标志码: A

文章编号: 1671-9379(2026)06-0010-10

DOI: 10.13969/j.jzgjgz.20250805001

Research on Intelligent Detection Methods for Bolt Defects in Steel Structures Based on Computer Vision

SUN Bo¹, WANG Zhen^{1,2}, ZHOU Xuejun^{2*}, LI Xiuling^{1,2}, FENG Shuaike²

(1. School of Transportation Civil Engineering, Shandong Jiaotong University, Jinan 250357, China; 2. School of Civil Engineering, Shandong Jianzhu University, Jinan 250101, China)

*Corresponding author: xuejunzhou@sdjzu.edu.cn

Abstract: To address issues in steel structure bolt defect detection such as low efficiency, high missed detection and false judgment rate of manual visual inspection, poor detection accuracy, weak anti-noise capability, and large number of computational parameters of traditional deep learning models, this paper proposes a bolt defect detection model based on improved YOLOv8. The model improves the backbone using poly-scale convolution and enhances spatial feature extraction capability through multi-dilation rate convolution kernels. It introduces CSPStage and DySample modules to optimize the neck, strengthens the efficiency and quality of multi-scale feature fusion, and improves the model's anti-noise capability in complex scenarios. For dataset acquisition, DJI Mavic 4 Pro unmanned aerial vehicle was used to collect images of steel truss joint bolts from the Pingyin Yellow River Bridge. Combined with CLAHE preprocessing and data augmentation strategies to improve image data quality, a steel structure bolt defect detection

收稿日期: 2025-08-05

基金项目: 国家自然科学基金(52278507), 山东省重点研发计划(重大科技创新工程)项目(2024CXGC10321), 山东省住房城乡建设科技计划(2024KYKF-JZGYH102)

作者简介:

孙 博(2002—), 男, 硕士研究生, 主要从事结构韧性提升及智慧运维方面的研究。E-mail: 2951641908@qq.com。

通信作者:

周学军(1965—), 男, 博士, 教授, 主要从事结构韧性提升及智慧运维方面的研究。E-mail: xuejunzhou@sdjzu.edu.cn。

dataset containing four states: rusty, loose, missing, and normal was constructed. Experimental results show that the improved YOLOv8-GDFPN model achieves a mean average precision (m_{AP}) of 83.5% and an accuracy of 88.1% on the self-built dataset, which are 4.9% and 4.5% higher than the YOLOv8 model, respectively. The model has 3.263 M computational parameters and an F_{PS} value of 181.8 frames per second, achieving a balance between detection accuracy and inference efficiency. This model can provide a reference for intelligent detection of bolt defects in complex outdoor scenarios.

Keywords: computer vision; bolt defect intelligent detection; YOLO algorithm; bolt image acquisition; image dataset construction; model optimization; anti-noise capability

钢结构凭借强度高、质量轻、施工便捷以及抗震性能好的优势,在现代工程建设领域中占据重要地位。螺栓连接作为节点连接的重要方式,具有施工简单、拆卸便捷和抗疲劳性能优异等特点,已被广泛应用于跨海大桥、城市高架桥等交通枢纽工程中^[1]。长期服役的钢结构桥梁受车辆荷载、结构振动及盐雾侵蚀、冻融循环、酸雨腐蚀等复杂环境因素的多重作用,螺栓易出现锈蚀、松动和缺失等病害。这些病害不仅会削弱螺栓的预紧力和连接强度,影响结构的整体性,甚至还会引发局部构件失效,导致桥梁垮塌等灾难性事故的发生。因此,及时、精准地检测和评估钢结构螺栓的健康状态,对保障结构运营安全、延长使用寿命具有重要意义^[2]。

在钢结构螺栓检测领域,传统人工检测方式存在高空作业安全风险高、目检效率低,且在复杂环境下易发生漏检、误判等问题。随着无人机技术的成熟,搭载高分辨率成像设备的无人机能够灵活穿梭于桥梁复杂结构空间,实现螺栓多角度高清图像的快速采集和位置形态的精准定位^[3]。同时,人工智能领域的深度学习算法凭借强大的图像特征识别与分析能力,在工业质检、故障诊断等领域展现出显著的应用成效。因此,将无人机采集的图像数据与深度学习算法相结合,构建基于图像的智能病害检测方法成为土木工程领域新的研究方向^[4]。CHA等^[5]借助深度学习技术设计了桥梁螺栓和螺母孔洞检测框架,并通过Python编程实现了性能评估。结果表明卷积神经网络在螺母、螺栓及螺母孔洞检测中表现卓越。FORKAN等^[6]开发了CorrDetector框架,运用基于卷积神经网络的深度学习方法对无人机拍摄的电信塔图像进行分析,实现了结构腐蚀的自动化监测。在桥梁螺栓病害检测方面,江旺玉等^[7]采用搭载高清变焦摄像头、激光测距仪和GPS定位控制系统的无人机采集螺栓图像,并利用改进的八方向Sobel算子对螺栓边缘进行分析,成功提取了螺栓病害相关信息。马耀安等^[8]提出了基于改进YOLOv3的深度学习神经网络分类模型,借助K-means聚类方法自动生成锚框尺寸,提升了模型对不同尺寸和形状螺栓病害的检测能力。面对螺栓病害检测数据集样本量小的问题,韦超等^[9]基于YOLOv8模型融合小目标

检测层、Focus层、Bottleneck CSP模块,同时结合图像采集的定位信息与桥梁三维数字模型,实现了螺栓病害的三维可视化定位,为病害评估与维修提供了直观依据。沈浩等^[10]提出了基于无人机平台和视觉检测算法的桥梁螺栓检测方法,先通过基于光流和逆滤波的图像运动模糊消除方法处理图像,再采用两阶段的螺栓检测方法确定螺栓的劣化情况。此外,宫涛等^[11]对基于视觉的螺栓故障检测方法进行全面综述,从双阶段算法、单阶段算法和级联检测模型等方面对基于深度学习的螺栓故障检测方法进行归纳总结,为后续研究提供了参考。

钢结构桥梁螺栓病害具有目标小、形态多样和抗环境干扰较弱等特点,现有模型的特征提取能力和抗噪性能不足,限制了其在实际工程中的应用。为此,本文提出一种基于多尺度卷积和动态采样机制的YOLOv8-GDFPN模型,通过引入多膨胀率卷积核增强空间特征提取能力,再结合动态采样策略优化网络特征融合结构,增强模型在小目标检测及复杂背景干扰下的螺栓病害特征提取性能,提升模型的鲁棒性。本文首先利用无人机对钢结构桥梁螺栓区域进行多角度、多场景的图像采集,获取不同光照和天气条件下的螺栓病害样本图像^[12]。采用LabelImg工具对样本图像中的螺栓锈蚀、松动和缺失等典型病害进行精细化标注,构建包含多场景特征的螺栓病害检测数据集。之后基于该数据集,对改进YOLOv8-GDFPN模型开展训练与测试。实验结果表明改进模型显著提升了螺栓病害检测的精度和准确率,在可视化分析中可成功检测出原模型遗漏的目标。同时,改进后的模型参数量以及帧率能够满足无人机轻量化搭载以及实时捕捉的要求,可为户外复杂场景下的螺栓病害智能检测提供参考。

1 图像采集及数据集构建

1.1 螺栓图像采集

本文的螺栓病害图像采集于平阴黄河大桥,该桥于1970年建成通车,位于山东省济南、聊城两市交界处,是105国道上重要的跨黄河公路桥。桥梁全长963.5 m,高14.8 m,宽10 m,由主桥和引桥两部分组成。主桥桥跨结构为两联(96+112+96) m三跨连续栓焊钢桁架,主桁

采用平行弦三角形体系,桁架高11.0 m,节间长8.0 m,两主桁横向中间距为10.0 m,杆件间通过节点板用高强螺栓连接。桥面采用正交异性钢桥面板,钢桥面板盖板采用14 mm 厚板,横向布置17根U肋,U肋间也采用螺栓连接。由于长期受动荷载作用及自然环境侵蚀,钢桁架中的部分高强螺栓已出现锈蚀、松动和缺失等病害,对桥梁结构安全构成威胁。

本文采用大疆消费级无人机DJI Mavic 4 Pro开展钢桥螺栓图像采集工作,该机型可搭载激光雷达、红外传感器及360°全向旋转万象云台等多种设备。其中,360°全向旋转云台凭借无死角的灵活转向能力,显著拓展了拍摄覆盖范围;配合激光雷达与红外传感器,在实现多角度精准拍摄的同时,保障了飞行安全。在拍摄作业中,无人机配备的由1亿像素哈苏主摄、4 800万像素中长焦镜头和5 000万像素长焦镜头组成的三摄系统可精准捕捉螺栓锈蚀、松动等损伤特征,为后续病害检测提供高质量的图像数据。无人机的技术参数如表1所示。

表1 无人机技术参数

Table 1 Technical parameters of unmanned aerial vehicle

设备	项目	参数
	尺寸	329 mm×390 mm×135 mm
	螺旋桨直径	26.7 mm
	云台俯仰角度	−164°~160°
	云台横滚角度	−40°~400°
	飞行时间	51 min
	工作环境温度	−10℃~40℃

表2 螺栓常见病害成因及危害

Table 2 Causes and hazards of common defects of bolt

病害种类	成因机理	工程危害
螺栓松动	预紧力不足、螺纹磨损或防松措施失效	连接节点刚度下降
螺栓锈蚀	长期暴露在潮湿、腐蚀性环境中导致金属表面发生化学反应	栓杆截面减小,节点承载力下降
螺栓缺失	承受过大的外荷载作用或发生疲劳断裂	节点刚度和承载力下降



图2 螺栓典型病害

Fig. 2 Typical bolt defects

螺栓图像采集过程中的飞行航线由大疆智图平台和智能避障系统构建^[13],该系统可规划覆盖主桥钢桁架各孔段及引桥关键结构区域的螺旋环绕、定点悬停拍摄路径,确保螺栓连接部位无死角拍摄。飞行过程中,无人机融合视觉传感、超声传感、激光传感等多源数据,实时感知周边环境,自动规避桥梁护栏、斜撑等复杂障碍物。针对关键节点启用特写拍摄模式,获取螺栓螺纹、螺母咬合面等重点区域高清图像,螺栓图像部分采集场景如图1所示。




图1 螺栓图像采集场景

Fig. 1 Bolt image acquisition scenes


1.2 数据集的标注及分类

钢结构螺栓的典型病害主要包括锈蚀、松动和缺失三类,其成因机理与工程危害^[14]如表2所示。为构建模型训练样本,本文选择开源图像标注工具LabelImg对数据集图像中的螺栓目标进行矩形框标注,标注类别分别为rusty(锈蚀)、loose(松动)、missing(缺失)和normal(正常)四类。考虑到实际拍摄的桥梁图像中四类样本存在分布不均衡问题,标注阶段通过融合COCO数据集补充典型病害样本,以提升标注数据的覆盖度与多样性。螺栓典型病害如图2所示。

1.3 图像预处理

由于在役钢桥螺栓长期暴露于户外复杂环境,导致图像易出现表面污渍、纹理模糊和阴影遮挡等问题。图像预处理技术能够通过噪声抑制、细节增强和光照矫正等手段显著改善图像数据视觉质量,为后续特征提取奠定基础。限制对比度自适应直方图均衡化(contrast limited adaptive histogram equalization, CLAHE)是一种

改进型图像预处理的算法,相较于传统直方图均衡化(histogram equalization, HE)算法,该算法通过将图像分成若干个小块,并对每个小块做直方图均衡化,然后限制其中每个小块像素的灰度级取值范围,在图像局部区域进行对比度优化,可在增强图像对比度的同时有效抑制噪声放大问题。采用CLAHE算法对部分螺栓节点图像进行预处理前后对比如图3所示。




a) 原始图像 b) CLAHE算法处理后的图像

图3 CLAHE算法处理前后对比

Fig. 3 Comparison before and after CLAHE algorithm processing

1.4 数据增强

在机器学习与计算机视觉领域,高质量数据集是保障模型泛化能力的基础。数据增强技术通过对原始样本实施一系列变换,可有效扩充数据样本的变异空间,从而增强模型在复杂场景下的鲁棒性与泛化能力。本文采用分阶段数据增强策略,实现数据集规模的扩充与标注类别的均衡化:在离线预处理阶段,对数据集执行随机翻转、旋转变换及自适应裁剪等几何变换,可在短时间内实现样本数量级的扩充;在线训练阶段,通过动态随机调整亮度、对比度及饱和度等像素级变换,进一步提升训练过程中的数据多样性。随机图像增强效果示例如图4所示。



a) 原始图像 b) 随机图像增强

图4 随机图像增强示例

Fig. 4 Random image enhancement

在目标检测任务中,数据增强需进行图像变换与边界框坐标协同调整。当对图像进行旋转、扭曲等空间几何变换时,边界框的像素坐标会发生非线性映射,此时需通过透视变换矩阵对边界框四个顶点进行坐标变换,再基于变换后顶点的像素位置重新计算最小外接矩形,以

确定新边界框的位置、尺寸及形态参数。

经图像预处理、关键点标注和分阶段数据增强处理后,钢结构螺栓病害检测数据集扩充至837张图像,累计标注螺栓目标框10 267个,完整覆盖螺栓锈蚀、松动、缺失及正常四类状态样本。采用分层随机抽样策略,按7:2:1比例划分训练集、验证集与测试集,确保各子集类别分布一致。以此方法所建立的螺栓病害检测数据集具备覆盖范围广,抗干扰能力强的特点,能够满足模型检测需求。

2 模型构建及优化

2.1 YOLOv8网络模型

YOLOv8是Ultralytics公司于2023年发布的目标检测模型,该模型采用“骨干-颈部-头部”的经典架构,支持目标检测、实例分割和图像分类三大任务,其网络结构如图5所示。相较于更早版本的YOLO系列模型,YOLOv8模型主要改进如下:骨干网络(Backbone)采用改进的CSPDarknet结构,将YOLOv5等版本中的C3模块替换为C2f模块,通过减少冗余计算和提升梯度传播效率实现轻量化;颈部网络(Neck)采用优化PAN-FPN结构,通过C2f模块替代冗余卷积层,增强特征融合效率;头部网络(Head)采用Anchor-Free设计与解耦头结构,结合DFL+CIoU损失函数,显著提升检测精度与速度。

然而,在螺栓病害检测场景中,该模型存在一定局限性:一是螺栓多为小目标,原模型对细微特征的提取与定位能力不足;二是户外拍摄环境易受光照变化、背景干扰等噪声影响,模型的抗干扰性能有待提升。因此,需针对螺栓病害检测的实际需求对YOLOv8进行改进。

2.2 骨干网络的改进

骨干网络在计算机视觉任务中扮演着核心特征提取器的角色,其特征表征能力直接决定模型对复杂场景的适应能力。传统YOLOv8模型采用的卷积模块虽注重尺度特征的提取,但受限于固定感受野和局部连接特性,在处理小目标及空间细节时存在缺陷。尤其是当螺栓目标尺度变化较大或存在遮挡时,易出现定位精度下降或漏检问题。为解决上述问题,本文引入多尺度卷积(poly-scale convolution, PSConv)替代原有卷积操作以强化模型对空间细节信息的捕捉能力^[15]。PSConv的核心原理是将周期性的膨胀率集成于单个卷积滤波器的不同卷积核中,使单一卷积层能以结构化方式覆盖从细粒度到粗粒度的特征尺度空间,在不增加参数和计算复杂度的前提下提升模型对尺度变化的鲁棒性,其操作流程如图6所示,图中不同的卷积核颜色代表不同的膨胀率。




图5 YOLOv8网络结构

Fig. 5 YOLOv8 network structure




图6 PSConv内部流程图

Fig. 6 PSConv internal flowchart

对于单个卷积层,输入特征为 $F \in R^{C_{in} \times H \times W}$, 其中 C_{in} 为通道数, H 和 W 分别为图像的高度和宽度。一组数量为 C_{out} 个、尺寸为 $K \times K$ 的滤波器 $G \in R^{C_{out} \times C_{in} \times K \times K}$ 分别与输入特征 F 进行卷积操作,得到具有 C_{out} 个通道的输出特征图 $H \in R^{C_{out} \times H' \times W'}$ 。PSConv 运算可以表示为:

$$H_{c,x,y} = \sum_{k=1}^{C_{in}} \sum_{i=-\frac{K-1}{2}}^{\frac{K-1}{2}} \sum_{j=-\frac{K-1}{2}}^{\frac{K-1}{2}} G_{c,k,i,j} F_{k,x+iD_{(c,k)},y+jD_{(c,k)}} \quad (1)$$

式中: $H_{c,x,y}$ 代表输出特征图 H 中的单个元素, $D_{(c,k)}$ 对应输出通道 c 和输入通道 k 之间的膨胀率。

2.3 颈部网络的改进

颈部网络作为目标检测任务的特征调度中心,负责多尺度特征融合与增强。在螺栓病害检测任务中,通过

优化颈部网络结构可有效整合特征金字塔网络(FPN)中不同层级的语义信息与位置细节,平衡螺栓局部病害特征与整体结构特征的表征能力,提升对遮挡干扰、尺寸差异等复杂工况的鲁棒性。

2.3.1 CSPStage 模块

针对现有模型在细微缺陷与整体空间分布特征融合能力不足的问题,本文引入 CSPStage 模块替代 C2f 模块,以实现深层语义信息与浅层空间信息的高效融合, CSPStage 模块结构如图 7 所示。CSPStage 模块将输入特征图分为两个并行分支,一条分支通过 1×1 卷积压缩通道,另一条分支在进行 1×1 卷积操作后通过 RepConv 模块和 3×3 卷积操作进行阶段性特征融合,最后两个分支特征经 Concat 合并后通过 1×1 卷积操作输出最终的融合特征。

CSPStage 模块通过非对称分支设计使得网络能够在不同的分支上学习不同层次的特征,有助于网络捕获图像的多尺度信息,提高了模型的表达能力。由于去掉了 C2f 结构的通道拆分操作,提升特征利用效率的同时降低了计算资源需求。

2.3.2 DySample 模块

在目标检测任务中,上采样通过提升低分辨率特征




图7 CSPStage模块网络结构

Fig. 7 CSPStage module network structure

图细节以增强模型对不同尺度目标的检测精度,是实现多尺度特征融合的核心步骤。YOLOv8模型采用的最近邻插值法或双线性插值法都是基于固定规则的上采样方法。该类方法需要根据输入特征图中最近或相邻的像素量来确定输出特征图的像素量,可能会导致细节模糊、边缘锯齿或关键信息的丢失,难以捕捉小目标特征。为解决上述问题,本文引入动态上采样(DySample)模块替代原有的插值采样方法,DySample模块网络结构如图8所示^[16]。


图8 DySample模块网络结构^[16]

Fig. 8 DySample module network structure

对于给定的上采样比例因子 s 和尺寸为 $C \times H \times W$ 的输入特征图 F ,将该特征图首先经采样点生成器处理,生成尺寸为 $2g \times sH \times sW$ 的采样集 S 。随后,网格采样函数使用采样集 S 中的位置对输入特征图 F 重采样,生成尺寸为 $C \times sH \times sW$ 的上采样后特征图 F' ,如式(2)所示:

$$F' = \text{grid_sample}(F, S) \quad (2)$$

采样点生成器结构如图9所示。输入特征图 F 通过输入通道数为 C 、输出通道数为 $2s^2$ 的线性层处理,生成尺寸为 $2s^2 \times H \times W$ 的偏移量 O 。为增强偏移量的灵活性,通过额外的线性变换和Sigmoid激活函数生成动态范围因子,调整偏移量的取值范围,偏移量的计算公式如下:

$$O = 0.5\text{sigmoid}(\text{linear}_1(x)) \cdot \text{linear}_2(x) \quad (3)$$

偏移量 O 生成后,通过像素重洗将其尺寸重塑为 $2s \times H \times W$,并与原始采样网格 G 相加得到采样集 S ,如式(4)所示:

$$S = O + G \quad (4)$$




图9 采样点生成器结构图

Fig. 9 Structural diagram of sampling point generator

采用上述改进策略后构建的YOLOv8-GDFPN模型结构如图10所示。

3 检测结果分析

3.1 实验环境

本实验基于YOLOv8官方默认参数配置,在所有模型的训练、测试与验证过程中均保持参数一致,并且所有实验均在相同软硬件环境下完成,以确保实验结果的可靠性与可复现性,实验环境配置如表3所示。训练阶段采用随机梯度下降(SGD)优化器,初始学习率设为0.01,权重衰减系数设置为0.0005。输入图像统一调整为 640×640 像素尺寸,模型训练总迭代次数为600轮,批量大小根据硬件性能设定为32。

3.2 评价指标

为对模型性能进行全面评估,本文采用准确率(Accuracy, A_{cc})、精确率(Precision, P)、召回率(Recall, R)、 F_1 值、平均准确率均值(m_{AP})和帧率(F_{PS})进行评估。准确率指所有预测正确的样本在总样本中所占的比例;精确率指模型预测为正类样本中实际为正类的比例;召回率指实际正类样本被正确预测的比例; F_1 值为精确率与召回率的调和平均值,可综合平衡二者性能,避免单一指标带来的偏差; m_{AP} 指计算每个类别上的平均精确率,再对所有类别求均值; F_{PS} 指单位时间内连续图像帧的生成数量。评价指标计算公式如下:

$$A_{cc} = \frac{T_P + T_N}{T_P + P_N + F_N + F_P} \quad (5)$$

$$P = \frac{T_P}{F_P + T_P} \quad (6)$$

$$R = \frac{T_P}{T_P + F_N} \quad (7)$$




图 10 YOLOv8-GDFPN 网络结构

Fig. 10 YOLOv8-GDFPN network structure

表 3 实验环境配置

Table 3 Experimental environment

名称	版本或型号
操作系统	Windows 11
架构	Cuda 11.8
框架	Pytorch 2.6.0
语言	Python 3.8.10
编程工具	Visual Studio Code
CPU	AMD R5 7500F, 3.70 GHz
GPU	NVIDIA RTX 4070 12 GB
运行内存	32 GB

式中: T_p 为真正类, F_p 为假正类, F_n 为假负类, T_n 为真负类, t_{pre} 为预处理时间, t_{inf} 为推理时间, t_{post} 为后处理时间。

3.3 模型训练

在完成 YOLOv8-GDFPN 模型构建后, 基于表 3 的实验环境进行模型训练, 训练结果如图 11 所示。训练过程中, 边界框损失和分类损失均呈现稳定下降趋势, 表明模型能够有效学习数据特征。验证集的边界框损失和分类损失虽存在小幅波动, 但整体呈下降趋势, 表明模型具备良好的泛化能力。

在性能指标方面, 模型精确率和召回率逐步提升并趋于稳定, 最终分别保持在 0.8 和 0.7 以上。交并比为 0.50 时, 模型的平均准确率均值 (m_{AP50}) 最终稳定在 0.8 左右, 在交并比从 0.50 增加至 0.95 且步长为 0.05 的条件下, 模型的平均准确率均值 ($m_{AP50-95}$) 指标表现良好。综合来看, 训练与验证指标收敛趋势一致, 表明模型训练过程稳定, 检测性能达到预期效果。

训练流程完成后, 系统将自动生成权重文件, 需将测试代码中的权重路径替换为新生成的 best 权重文件, 并确保

$$F_1 = \frac{2T_p}{2T_p + F_p + F_n} \quad (8)$$

$$m_{AP} = \frac{1}{N} \sum_{i=1}^N A_p, A_p = \int_0^1 P(R) dR \quad (9)$$

$$F_{PS} = \frac{1000}{t_{pre} + t_{inf} + t_{post}} \quad (10)$$




图 11 训练参数变化图

Fig. 11 Plot of changes in training parameters

其他相关参数设置与训练阶段完全一致。完成上述操作后运行测试代码,系统随即输出测试结果。实验对比结果显示,改进后的算法在桥梁螺栓病害检测任务中的性能显著优于YOLOv8原模型的性能,在相同检测任务中,改进模

型 m_{AP} 指标达83.5%,有效克服了原始版本的局限性,能够更加高效、准确地完成桥梁病害的识别任务。

3.4 消融实验

为系统评估YOLOv8-GDFPN模型中骨干和颈部网络改进策略对目标识别性能的贡献,本文在自建数据集上进行了消融对比实验。实验以YOLOv8原始模型为基准,在保持检测头、训练策略、数据集、数据增强策略以及所有参数完全一致的前提下,依次构建并训练了6个检测模型,各项改进策略对螺栓病害的检测结果如表4所示,其中 P_{arams} 和 F_{LOPs} 分别代表模型参数量和浮点运算量。从表中可以看出,仅采用PSCnv卷积操作虽然降低了模型的参数量,但对模型准确率的提高并不明显, m_{AP} 指标甚至出现了下降;仅采用CSPStage和DySample优化的模型虽然实现了 m_{AP} 、准确率等指标的提升,但增加了浮点运算量。而本文构建的YOLOv8-GDFPN模型的 m_{AP} 指标达到了83.5%,相较于前五种模型的 m_{AP} 分别提升了4.9%、5.5%、3.8%、1.8%和1.3%; F_1 值达到了74.0%,相较于前五种模型 F_1 值分别提升了11.4%、6.0%、6.2%、4.3%和1.1%。消融实验结果表明,YOLOv8-GDFPN模型中对骨干网络和颈部网络的改进分别发挥了使模型轻量化和提升精度的作用。

3.5 对比实验

为验证YOLOv8-GDFPN模型的性能优势,在相同的实验参数设置下,通过对比实验分析了其与YOLO系列其他算法的性能差异,对比实验结果如表5所示。实验结果表明,YOLOv8-GDFPN在 m_{AP} 、准确率等关键指标上显著优于同类算法:YOLOv8-GDFPN模型的 m_{AP} 值达到了83.5%,较YOLOv5、v8和v10版本分别提高了6.5%、4.9%和10.2%;YOLOv8-GDFPN模型的准确率达到88.1%,较其他版本分别提高了6.5%、4.9%和10.2%,YOLOv8-GDFPN模型的 F_1 值达到了74.0%,较其他版本分别提高了3.2%、11.4%和5.3%。YOLOv8-GDFPN模型通过优化多尺度特征融合机制,有效提升了模型的检测精度。

在检测效率方面,YOLOv8-GDFPN的参数量为3.263 M、浮点运算量为8.3 G, F_{PS} 为181.8帧 $\cdot s^{-1}$,尽管参数量和浮点运算量略有增加,但推理速度仍保持在较高水平,实现了检测精度与检测效率的良好平衡。

3.6 可视化分析

为更直观地验证模型在实际应用场景中的检测性能,本文采用数据集外的典型病害图像进行可视化分析,对比YOLOv8和YOLOv8-GDFPN模型的目标检测效果如图12所示。从图中可以看出,YOLOv8原模型在处

Fig. 12 Visual image comparison

参考文献:

- [1] 孙虎, 肖达, 侯俊. 螺栓连接结构孔边损伤定量化监测技术研究进展[J]. 航空科学技术, 2025, 36(7): 8-18. DOI:10.19452/j.issn1007-5453.2025.07.002.
SUN Hu, XIAO Da, HOU Jun. Research progress of hole-edge damage quantification technology for bolted joints[J]. Aeronautical Science & Technology, 2025, 36(7): 8-18. DOI:10.19452/j.issn1007-5453.2025.07.002. (in Chinese)
- [2] 朱亚飞, 任伟新, 王亚飞. 基于桥梁监测系统振动响应的浮吊船-悬索桥主梁碰撞荷载估算与分析[J]. 中国公路学报, 2024, 37(9): 107-118. DOI:10.19721/j.cnki.1001-7372.2024.09.009.
ZHU Yafei, REN Weixin, WANG Yafei. Impact force estimation and analysis of collision between floating crane and main girder of suspension bridge using vibration responses in bridge monitoring system[J]. China Journal of Highway and Transport, 2024, 37(9): 107-118. DOI:10.19721/j.cnki.1001-7372.2024.09.009. (in Chinese)
- [3] 鞠定超, 张云开, 黄永, 等. 面向智能运维的交通基础设施视觉感知与诊断[J]. 土木工程与管理学报, 2025, 42(3): 1-15. DOI:10.13579/j.cnki.2095-0985.2025.20250087.
JU Dingchao, ZHANG Yunkai, HUANG Yong, et al. Visual perception and diagnosis of transportation infrastructure for intelligent operation and maintenance[J]. Journal of Civil Engineering and Management, 2025, 42(3): 1-15. DOI:10.13579/j.cnki.2095-0985.2025.20250087. (in Chinese)
- [4] 崔阔, 罗纯坤, 邱师津, 等. 基于数据深度增强的钢桥螺栓脱落智能检测方法研究[J]. 桥梁建设, 2024, 54(2): 39-47. DOI:10.20051/j.issn.1003-4722.2024.02.006.
CUI Chuang, LUO Chunkun, QIU Shijin, et al. An intelligent bolt shedding detection method for steel bridges based on depth data enhancement[J]. Bridge Construction, 2024, 54(2): 39-47. DOI:10.20051/j.issn.1003-4722.2024.02.006. (in Chinese)
- [5] CHA Y J, YOU K, CHOI W. Vision-based detection of loosened bolts using the Hough transform and support vector machines[J]. Automation in Construction, 2016, 71: 181-188. DOI:10.1016/j.autcon.2016.06.008.
- [6] FORKAN A R M, KANG Y B, JAYARAMAN P P, et al. CorrDetector: A framework for structural corrosion detection from drone images using ensemble deep learning[J]. Expert Systems with Applications, 2022, 193: 116461. DOI:10.1016/j.eswa.2021.116461.
- [7] 江旺玉, 王乐, 姚叶鹏, 等. 多尺度特征聚合扩散和边缘信息增强的小目标检测算法[J]. 计算机工程与应用, 2025, 61(7): 105-116.
JIANG Wangyu, WANG Le, YAO Yepeng, et al. Multi-scale feature aggregation diffusion and edge information enhancement small object detection algorithm[J]. Computer Engineering and Applications, 2025, 61(7): 105-116. (in Chinese)
- [8] 马耀安, 黄裕婷, 张健豪, 等. 基于K-means-CNN的复杂牌号混合合金样品分类研究[J]. 光谱学与光谱分析, 2025, 45(7): 1946-1952. DOI:10.3964/j.issn.1000-0593(2025)07-1946-07.
MA Yaoan, HUANG Yuting, ZHANG Jianhao, et al. K-means-CNN-based classification study of mixed alloy samples of complex grades[J]. Spectroscopy and Spectral Analysis, 2025, 45(7): 1946-1952. DOI:10.3964/j.issn.1000-0593(2025)07-1946-07. (in Chinese)
- [9] 韦超, 钱春雨, 黄启鹏, 等. 基于YOLOv8n的表格线检测改进模型[J]. 计算机工程与应用, 2025, 61(2): 112-123. DOI:10.3778/j.issn.1002-8331.2405-0165.
WEI Chao, QIAN Chunyu, HUANG Qipeng, et al. Improved model for table-line detection based on YOLOv8n[J]. Computer Engineering and Applications, 2025, 61(2): 112-123. DOI:10.3778/j.issn.1002-8331.2405-0165. (in Chinese)
- [10] 沈浩, 江臣, 陈宇文, 等. 基于深度学习的钢桁架桥螺栓病害智能识别方法[J]. 南京工业大学学报(自然科学版), 2020, 42(5): 608-615. DOI:10.3969/j.issn.1671-7627.2020.05.009.
SHEN Hao, JIANG Chen, CHEN Yuwen, et al. Intelligent identification method for bolt diseases of steel truss bridge based on deep learning model[J]. Journal of Nanjing University of Technology (Natural Science Edition), 2020, 42(5): 608-615. DOI:10.3969/j.issn.1671-7627.2020.05.009. (in Chinese)
- [11] 宫涛, 杨建华, 庄絮竹, 等. 螺栓松动故障监测实验研究综述[J]. 机械设计与制造, 2024(2): 354-363. DOI:10.19356/j.cnki.1001-3997.20230824.019.
GONG Tao, YANG Jianhua, ZHUANG Xuzhu, et al. Review of experimental research on bolt looseness monitoring[J]. Machinery Design & Manufacture, 2024(2): 354-363. DOI:10.19356/j.cnki.1001-3997.20230824.019. (in Chinese)
- [12] SHANG Z Q, QIN X, ZHANG Z J, et al. Bolt loosening and preload loss detection technology based on machine vision[J]. Buildings, 2024, 14(12): 3897. DOI:10.3390/buildings14123897.
- [13] 冒建亮, 王展, 周昕, 等. 基于深度强化学习的机械臂动态避障算法设计与实验验证[J]. 实验技术与管理, 2025, 42(4): 78-85. DOI:10.16791/j.cnki.sjg.2025.04.010.
MAO Jianliang, WANG Zhan, ZHOU Xin, et al. Design and experimental verification of a dynamic obstacle avoidance algorithm for robot manipulators based on deep reinforcement learning[J]. Experimental Technology and Management, 2025, 42(4): 78-85. DOI:10.16791/j.cnki.sjg.2025.04.010. (in Chinese)
- [14] 徐刚年, 王来永, 李伟, 等. 胜利黄河大桥病害高强螺栓节点修复及桥面板补强技术[J]. 桥梁建设, 2023, 53(6): 151-158. DOI:10.20051/j.issn.1003-4722.2023.06.020.
XU Gangnian, WANG Laiyong, LI Wei, et al. Rehabilitation of damaged high-strength bolted joints and bridge deck strengthening techniques for Shengli Huanghe River bridge[J]. Bridge Construction, 2023, 53(6): 151-158. DOI:10.20051/j.issn.1003-4722.2023.06.020. (in Chinese)
- [15] LI D, YAO A B, CHEN Q F. PSConv: Squeezing feature pyramid into one compact poly-scale convolutional layer[C]//Computer Vision-ECCV 2020. Cham: Springer, 2020.
- [16] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris: IEEE, 2024.