

基于 YOLOv5 的轻量化桥梁缺陷识别

王琳虹¹, 刘宇阳¹, 刘子昱¹, 鹿应佳², 张宇恒², 黄桂树²

(1. 吉林大学 交通学院, 长春 130012; 2. 吉林省交通运输综合行政执法局, 长春 130012)

摘要:以 YOLOv5 算法为基础框架, 通过引入 FasterNet 轻量化网络结构优化特征提取过程, 降低模型计算复杂度; 结合卷积块注意力模块 (CBAM) 注意力机制, 提高模型对缺陷特征的关注度; 采用 SIOU 损失函数改进边界框回归精度, 提升定位准确性。实验结果表明: 本文改进模型在自建桥梁缺陷数据集上取得了显著效果, 精确度和 mAP 分别达到 81.2% 和 71.5%, 较基准模型有明显提升。本研究为桥梁缺陷的智能化检测提供了技术支撑, 对推动桥梁养护管理的数字化转型具有重要意义。

关键词: 交通运输系统工程; 缺陷检测; 深度学习; 无人机视角

中图分类号: U447 **文献标志码:** A **文章编号:** 1671-5497(2025)09-2958-11

DOI: 10.13229/j.cnki.jdxbgxb.20250539

Defect recognition of lightweight bridges based on YOLOv5

WANG Lin-hong¹, LIU Yu-yang¹, LIU Zi-yu¹, LU Ying-jia², ZHANG Yu-heng², HUANG Gui-shu²

(1. College of Transportation, Jilin University, Changchun 130022, China; 2. Jilin Provincial Comprehensive Administrative Law Enforcement Bureau of Transportation, Changchun 130012, China)

Abstract: Based on the YOLOv5 algorithm, the feature extraction process was optimized by introducing the FasterNet lightweight network structure to reduce the computational complexity of the model. Combining Convolutional Block Attention Module (CBAM) attention mechanism to improve the model's attention to defect features. Adopting the SIOU loss function to improve the accuracy of bounding box regression and enhance localization accuracy. The experimental results show that the improved model has achieved significant results on the self built bridge defect dataset, with accuracy and mAP reaching 81.2% and 71.5%, respectively, which is a significant improvement compared to the benchmark model. This study provides technical support for the intelligent detection of bridge defects, which is of great significance for promoting the digital transformation of bridge maintenance management.

Key words: engineering of communications and transportation system; defect detection; deep learning; UAV perspective

0 引言

由于我国高速公路里程长、巡检工作量大, 传

统的人工巡检方式存在事故风险高、效率较低等问题; 若使用悬臂车进行详细的桥梁巡检不仅占

收稿日期: 2025-06-19.

基金项目: 国家自然科学基金面上项目 (52472359); 吉林省交通运输创新发展支撑 (科技) 项目 (2023-1-13).

作者简介: 王琳虹 (1984-), 女, 教授, 博士. 研究方向: 驾驶安全, 公路安全. E-mail: wanghonglin0520@126.com

用空间较大,而且价格昂贵^[1]。而对比分析无人机桥梁检测技术及悬臂车检测技术,在常规检查项目中,前者的成本低,且作业周期较短,拥有更高的经济效益和时间效益^[2,3]。因此,利用无人机采集高速区域内的桥梁缺陷数据,搭配目标检测算法,对桥梁缺陷类型进行快速识别判定,不仅能减少巡检时间、降低成本、缩短作业周期以及提高巡检效率,还可以保障执法人员在巡检过程中的安全。传统目标检测方法主要依赖人工设计的特征提取和机器学习算法,虽然计算效率较高,但其泛化能力较差,难以适应复杂多变的检测场景。随着深度学习技术的发展,这类方法因检测精度有限、适应性不足等缺陷已逐渐被淘汰。

随着智能时代的到来,深度学习技术被广泛应用于工业的目标检测任务中,并取得了显著成果^[4-6]。目前,基于深度学习的目标检测算法大致分为一阶段检测和二阶段检测两种^[7]。一阶段检测原理为直接在输入图像上密集地生成候选目标框,并对框进行分类和边界框回归。张河山等^[8]通过引入自适应空间特征融合模块,并嵌入坐标注意力机制,替换损失函数以提升无人机航拍视角下小目标检测精度。Yang等^[9]改进YOLOv3的损失函数,提高远距离、小尺寸及遮挡目标的检测准确性。Cao等^[10]在YOLOv5基础上整合RepConv、Transformer Encoder和BiFPN模块,提升不同尺寸物体的检测精度。许晓阳等^[11]提出了KD-YOLO-DW算法,在Head层集成GhostNet V2模块,降低了模型的参数量和计算需求。二阶段检测先通过生成候选目标框的区域建议网络(Regional suggestion network, RPN)和边界框的分类回归网络,再利用RPN生成候选框。彭卫兵等^[12]通过替换二阶段检测R-CNN算法中的骨干网络提升模型的整体性能。陈昭俊^[13]使用类平衡调整类别权重,在保证较多类别精度的同时提升少数类别的精度。二阶段检测方法虽然在大目标和复杂场景中具有较强的精度性能,但由于其计算量大,导致整体运行速度相比于一阶段检测方法过于缓慢。而YOLO作为一阶段检测方法的代表,将目标检测任务视为单一回归问题,直接从图像生成边界框和类别预测,在保持较高检测精度的同时显著提升了检测速度,满足了对桥梁损毁的实时高精度检测要求。

在使用YOLO进行桥梁缺陷检测的研究中,

存在3类关键挑战:①小目标缺陷在复杂桥面背景中易被漏检;②现有研究大多仅对裂痕的识别进行了深入研究,不断拓展检测方法、提升单一类别的检测精度^[8],但对其他类别桥梁缺陷的研究较少^[13];③无人机巡检场景对算法实时性与精度的平衡性要求高,难以兼顾。YOLOv5模型相较于其他YOLO模型,在保持高精度的同时实现了更好的轻量化和实时性,并因其结构简洁、部署方便在工业检测场景中被广泛应用。因此,本文使用YOLOv5模型作为基础模型,对模型结构进行优化改进,实现轻量化,以更好地满足实际工程应用的需求。此外,还通过算法改进提升检测精度和速度,提升对多类别缺陷的泛化能力,为桥梁缺陷的智能化巡检提供技术支持。

1 桥梁缺陷数据采集

1.1 桥梁缺陷类别确定

执法人员在巡检过程中不易观察到需要翻越护栏通过楼梯绕行下去的缺陷类型,除了桥体裂缝之外还包括桥面沉降、支座墩台损坏、钢结构锈蚀以及排水不良等。本文选取缺陷中发生率较高,同时数量均衡的3类缺陷,即桥梁钢结构锈蚀、桥体裂缝以及桥侧大面积剥落,将它们划定为最终需要检测的种类。除了具体的缺陷种类外,本文还纳入了对桥梁整体的检测,不仅有助于确定缺陷区域,还能帮助巡检人员了解需要修复桥梁的具体类型。

1.2 桥梁缺陷数据采集

网上公开数据集数据不全面,无法覆盖本文的缺陷类别。因此通过无人机(大疆御3Pro)飞行收集各类桥梁缺陷的图像,构建桥梁缺陷图像数据集作为后续研究的基础。所采集区域为吉林省内缺陷较多的高速公路区域,具体线路如图1所示,采集区域包括通化、敦化、靖宇境内的抚通高速、鹤大高速以及松原境内的珲乌高速,共调查高速线路长426.7 km,拍摄过程保持缺陷位置位于无人机拍摄位置中央。取部分采集数据进行分析,发现桥体裂缝、桥梁钢结构锈蚀和桥侧大面积剥落为3种主要损毁类型,占比分别为40.3%、30.6%和27.9%,因此,选取这3种损毁类型作为研究对象。采集样本如图2所示。

为提高模型的广泛适用性和准确性,在桥梁缺陷数据集中融入一定数量的负样本图像。所选



图 1 数据采集区域

Fig. 1 Data collection area



(a)桥体裂缝 (b)桥梁钢结构锈蚀 (c)桥侧大面积剥落

图 2 采集样本示意图

Fig. 2 Schematic diagram of sample collection

取的负样本为高速公路场景下的纯净背景图,确保这些图像中不含有任何桥梁元素,如图 3 所示。这样的数据扩充策略能帮助模型更精准地区分桥梁目标与复杂背景,有效降低因背景干扰导致的误检率,同时增强模型在不同环境下的泛化能力,使其在面对非桥梁场景时仍能保持对桥梁目标(包括损毁状态)的准确识别,进而提升检测结果的可靠性和鲁棒性。



(a)原图 (b)背光处理图

图 3 背光处理对比图

Fig. 3 Contrast diagram of backlight processing

1.3 桥梁缺陷数据构建

由于所采集到的图像是在不同光照和天气条件下使用无人机拍摄得到的,通过背光处理调整阴影部分亮度,可以使图片的可读信息更加清晰。这里设定亮度阈值为 128,并获取图片的全局平均亮度,然后对每个像素施加一个基于“128减平均值”的固定偏移量,实现将图像整体平均亮度趋向于中等值 128 的效果,处理效果如图 3 所示。

为了防止数据在拍摄以及传输过程中出现损伤而导致无法识别,通过高斯噪声模拟存在损伤的图片,这里设定添加高斯噪声初始均值为 0,初始方差为 0.005,并在处理过程中通过 OpenCV 的滑动条(Trackbar)动态调整参数,均值为 0~0.8;方差为 0~0.04,处理效果如图 4 所示。针对不同距离和不同角度拍摄图片大小和方向不一致的问题,采用水平翻转和镜像、剪裁以及空间尺寸缩放等操作对图像进行预处理,并将处理后的图片和处理前的图片一并输入模型进行训练,这不仅可以增加数据集的数量、提高样本的丰富性,还可以让模型提前适应不同照片的质量问题、使得算法具有普适性,最终达到模拟实际情况的目的。



(a)添加噪声前 (b)添加噪声后

图 4 噪声添加对比图

Fig. 4 Contrast diagram of noise addition

经过前期对桥梁及其缺陷图像的预处理后,即可通过使用 LabelImg 标注工具对得到的图像进行人工标注。共标注 9 920 幅高分辨率图像,涵盖 3 个类别,分别为桥体裂缝、桥梁钢结构锈蚀和桥侧大面积剥落。总共标注了 57 656 个带有标签的对象,每类标签个数分别为 14 422、12 930 和 11 476 个。按照 8:1:1 的比例将货车数据集的图片和标注文件随机划分至训练集、验证集以及测试集中,其中训练集图片 7 936 张,验证集图片 992 张,测试集图片 992 张。

2 桥梁缺陷检测模型构建

在桥梁缺陷检测领域,复杂多变的现场环境对目标检测算法提出了严峻挑战,要求算法具备快速响应能力和高精度识别性能。综合比较了现有目标检测算法^[7-9],本文选择 YOLO 系列算法作为基础框架,主要基于以下考量:其一,YOLO 算法具有显著的实时性优势,其检测机制在视频监控、无人驾驶、工业检测及医学图像分析等领域已得到广泛应用验证;其二,YOLO 的开源特性及其模块化架构设计为算法优化提供了良好基础,便于针对桥梁缺陷特点进行定制化改进,如扩

展缺陷类别识别范围、增强微小目标检测能力等,从而全面提升检测系统的实用性和可靠性^[14-16]。

2.1 底层框架选择

虽然 YOLOv8 作为更新版本引入了多项改进,包括更复杂的模型结构和增强的特征提取能力,这些改进虽能提升检测精度,但也显著增加了对硬件资源和计算能力的要求。相比之下,YOLOv5 在检测精度和速度之间实现了更好的平衡,其成熟的框架和优化策略能够以较低的计算代价实现高效的目标检测。具体而言,在选择 YOLO 的底层框架时,从头部设计和预测框生成方式两方面考虑^[17],认为 Ultralytics 版本的 YOLOv5 相较于 YOLOv8 更能满足桥梁巡检的需求。

(1)在目标检测算法的头部设计中,耦合头是指将分类任务和回归任务的特征提取与预测过程进行联合优化的设计方式,其特征提取网络共享参数,输出层同时预测目标类别和边界框信息;而非耦合头则采用分离式设计,通过独立的网络分支分别处理分类和回归任务,具体结构如图 5 和图 6 所示。YOLOv8 采用非耦合头设计,取消了独立的对象预测损失函数,转而通过分类损失中的区域对象存在概率进行判断,并将边界框回归损失与分类损失完全分离。然而,在检测类别数量有限的场景下,耦合头设计能够更好地实现特征信息的整合和利用,提高特征提取效率。鉴于本文主要针对 3 类桥梁缺陷的识别,检测类别数量较少,采用耦合头设计的 YOLOv5 能够有效减少特征提取过程中的冗余计算,降低模型复杂度,从而实现模型的轻量化设计并提升检测效率,因此,选择 YOLOv5 的耦合头。




图 5 YOLOv5 头部结构

Fig. 5 Head structure of YOLOv5




图 6 YOLOv8 头部结构

Fig. 6 Head structure of YOLOv8

(2)在目标检测算法的预测框生成机制中,Anchor-Based 方法通过在特征图上预定义一系列具有不同尺度和长宽比的锚框,将其作为候选检测区域,网络通过预测锚框的偏移量精确定位目标。而 Anchor-Free 方法(无锚框的方法)则摒弃了预定义锚框的设计,直接预测目标中心点位置及其到边界框四边的距离,两种预测框生成方式如图 7 所示。YOLOv5 采用 Anchor-Based 方法,该方法基于训练集中目标物体的统计特征,预先计算出一组能够覆盖大多数目标形状的锚框,并通过网络微调实现精确的目标定位。相比之下,YOLOv8 采用 Anchor-Free 方法,通过中心点定位和边界距离预测实现目标检测。考虑到本文主要检测的桥梁缺陷多为小尺度目标,Anchor-Based 方法能够生成更密集的预测框,显著提升




图 7 Anchor-Based 和 Anchor-Free 的预测原理

Fig. 7 Prediction principles of Anchor-Based and Anchor-Free

小目标的召回率,同时其直接回归边界框的机制有利于提高检测精度。因此,基于本文场景中的目标特征和检测需求,选择采用 Anchor-Based 方法的 YOLOv5 更为适宜。

综上所述,YOLOv5 在桥梁缺陷识别任务中主要面临两个问题:①对小目标和极不规则缺陷区域的检测精度不足;②对多尺度、多区域缺陷特征的关注意度不够。前者主要是由于模型的特征提取能力有限,在处理高复杂度场景时难以充分捕捉细微的缺陷特征,导致缺陷区域定位不够精确;后者则由于缺陷类型视觉特征的显著差异及其多尺度分布特性,传统 YOLOv5 模型缺乏有效的特征融合机制,难以同时兼顾不同尺度和区域的缺陷特征,从而遗漏部分重要的缺陷细节信息。

为了解决上述问题,本实验针对 YOLOv5 模型做了以下几点改动。

(1)更新混合架构:将 FasterNet 网络结构中的部分卷积与卷积块注意力模块(Convolutional block attention module, CBAM)注意力机制有效结合,提升模型的特征提取和学习能力,使其能够更准确地捕捉复杂特征,增强模型的表达能力。

(2)优化损失函数:对预测框与真实框的几何关系进行更加精细的优化,提升边界匹配精度。在处理桥梁缺陷定位时,更加精准地捕捉损坏区域的边界和位置。

(3)优化超参数:通过遗传算法对模型的超参数进行优化,使改进后的模型更适合桥梁缺陷类型检测。

2.2 网络结构的修改

传统特征提取速度较慢的原因在于特征表示的冗余计算以及对关键信息的关注不足,导致整体计算效率降低。针对桥梁缺陷识别模型中特征提取效率较低的问题,本文提出了一种基于 FasterNet 部分卷积和 CBAM 注意力机制的优化方案。具体而言,通过引入 FasterNet 中的部分卷积操作,有效降低模型的计算复杂度,同时保持优异的特征提取能力;结合 CBAM 注意力机制模块,实现对特征图通道维度和空间维度的动态权重调整,从而增强模型对关键特征的聚焦能力。实验结果表明:该融合策略不仅简化了模型结构,还在保证检测精度的同时显著提升了模型的运行效率,为桥梁缺陷的智能识别提供了更优的解决方案。

2.2.1 FasterNet 的部分卷积

FasterNet 模型^[18]的功能是将 YOLOv5 模型中的跨阶段局部网络(Cross stage partial network, CSP)模块替换为 FasterNet Block 模块。FasterNet Block 模块操作流程如图 8 所示,分为两个分支:一个分支经过部分卷积(PConv)和卷积(Conv)模块后得到特征图 1,特征图 1 通过批归一化(Batch normalization, BN)层归一化以及修正线性单元(Rectified linear unit, ReLU)非线性激活后得到特征图 2,特征图 2 和另一条分支逐元素相加完成输出。




图 8 FasterNet Block 模块结构

Fig. 8 Module structure of FasterNet Block

在 FasterNet Block 模块中,PConv 代表部分卷积,其独特之处在于能够切实有效地减少模型的运算量和内存访问量,进而显著提升运算速度。部分卷积示意图如图 9 所示,内存访问量 P_{mac} 和 P_{flops} 浮点运算次数分别如下所示:

$$P_{mac} = h \times w \times 2c_p + k^2 \times c_p^2 \quad (1)$$

$$P_{flops} = h \cdot w \cdot (k^2 \cdot c_p \cdot c + c \cdot (c - c_p)) \quad (2)$$

式中: h 为特征图的高度; w 为特征图的宽度; k 为卷积核的尺寸大小; c 为输入通道的总数; c_p ($c_p < c$) 为参与卷积的通道数。




图 9 部分卷积示意图

Fig. 9 Schematic diagram of partial convolution

虽然只使用 c_p 通道进行空间特征提取,但其余通道无须从特征图中移除,而是直接映射获得完整的信息,同时为添加注意力机制做铺垫。

文献[18,19]使用 Frobenius 范数计算参与卷积的通道数 c_p 在不同比例下的计算效果。本文在原先的基础上将比例扩大到 8 个点,从 1/16 到 1/2,每两个比例之间相差 1/16,进行更为详细的对比分析,结果如图 10 所示。综合考虑认为使用 1/4 这个比例更适用于本文数据集。




图 10 不同比例下的效果点线图

Fig. 10 Effect point-line diagram under different proportions

2.2.2 注意力机制的添加

将主干网络(Backbone)层的 CSP 模块替换为 FasterNet Block 模块提升检测效率后,进一步在 Backbone 和头部结构(Head)连接处引入 CBAM 注意力机制^[20],强化桥梁缺陷特征提取,使模型更聚焦于关键信息,提升对破坏类型的辨识精度。CBAM 结构^[21]如图 11 所示,其流程为:特征图先经通道注意力模块,通过最大池化和平均池化获取通道信息;再经多层感知器和激活函数生成通道注意力特征 MC;随后,特征图输入空间注意力模块,通过通道池化和 1×1 卷积降维,经 Sigmoid 激活生成空间注意力特征 MS。CBAM 模块的引入解决了原网络无注意力偏好的问题,使模型更关注目标区域。改进后的 YOLOv5 网络结构如图 12 所示。




图 11 CBAM 网络结构图

Fig. 11 Network structure diagram of CBAM

2.3 损失函数的改进

在复杂环境中,特别是桥梁缺陷识别任务中,模型可能面临精度不足的问题,这主要是因为现




图 12 改进后 YOLOv5 的结构图

Fig. 12 Structure diagram of improved YOLOv5

有损失函数在目标定位和分类方面的优化能力有限,容易退化为普通的交并比(Intersection over Union, IoU)损失函数,该指标为目标检测中衡量预测框与真实框重叠程度的核心指标,通过计算两框交集面积与并集面积的比值量化重合度,取值为[0,1]。为此,本文通过使用更高效的损失函数,提升模型的识别准确率,使其能够更精准地定位和识别桥梁缺陷区域。新损失函数不仅强化了对小目标和边界模糊目标的检测能力,还能更好地适应高速公路巡检场景中的复杂性和多样性,从而提升模型的鲁棒性和实用性。

2.3.1 经典的损失函数

YOLOv5 原始模型使用的损失函数主要是广义交并比(Generalized intersection over union, GIoU)^[22],图 13 为 GIoU 的示意图,引入 GIoU 的目的是解决预测框与真实框可能不重叠时的问

题。相较于原始的 IoU,GIoU 增加了一个能够完全包含目标框 A 和预测框 B 的最小外接矩形框 C。GIoU 和损失函数 L_{GIoU} 的计算公式分别为:

$$GIoU = IoU - \frac{|S_C - (S_{A \cup B})|}{|S_C|} \tag{3}$$

$$L_{GIoU} = 1 - GIoU \tag{4}$$

式中: S_C 为最小外接矩形的面积; $S_{A \cup B}$ 为预测框和真实框的并集面积;IoU 为目标检测中衡量预测框和真实框重叠程度,计算得出的 GIoU 是用于替换 IoU 的距离度量指标; L_{GIoU} 为损失函数,通




图 13 GIoU 示意图

Fig. 13 Schematic diagram of GIoU

过最小化这个损失函数,可以使预测框更加接近真实框。但当两个预测框处于包含关系或高宽相同且处于同一水平面时,缩放交并比(Scaled intersection over union, GIoU)可能会退化为 IoU;以及当目标具有复杂的形状或方向时,GIoU 可能无法准确反映预测框与真实框之间的重合度和位置关系。

2.3.2 改进的损失函数

为了解决处于同一水平面退化的问题以及更有效地应对宽高相同或者其他复杂形状的场景,分别引入距离损失和形状损失进一步优化模型性能,提高检测过程中对预测框形状的敏感度。这两点正好符合 SIoU 的运行逻辑。因此,本文通过改进 SIoU 替换 GIoU,提升模型精度。改进后的 SIoU^[23]及对应的损失函数 L_{SIoU} 计算公式为:

$$\text{SIoU} = \text{IoU} - \frac{\Delta}{3} - \frac{2 \times \Omega}{3} \quad (5)$$

$$L_{\text{SIoU}} = 1 - \text{SIoU} \quad (6)$$

式中: Δ 为距离损失, Δ 不仅考虑了预测框中心与真实框中心之间的距离归一化位置偏差相关量 ρ_t ,还引入角度损失 Λ ,以提供更平滑和鲁棒性更好的梯度, Δ 、 Λ 和 ρ_t 的具体计算公式如下所示。

$$\Delta = \sum_{t=x,y} (1 - e^{-(2-\Lambda)\rho_t}) \quad (7)$$

$$\Lambda = 1 - 2 \times \sin^2(\arcsin(x) - \frac{\pi}{4}) \quad (8)$$

$$\rho_t = \begin{cases} \left(\frac{b_{cx}^{\text{gt}} - b_{cx}}{c_w} \right)^2, & t = x \\ \left(\frac{b_{cy}^{\text{gt}} - b_{cy}}{c_h} \right)^2, & t = y \end{cases} \quad (9)$$

式中: x 为预测框中心和真实框中心连线与水平方向的夹角; b_{cx}^{gt} 和 b_{cy}^{gt} 分别为真实框中心点的横、

纵坐标; b_{cx} 、 b_{cy} 为预测框中心点的横、纵坐标; c_w 、 c_h 分别为预测框与真实框的最小外接矩形的宽度和高度。

式(5)中 Ω 为形状损失,通过宽高比 ω 使得模型在训练过程中能够更好地适应数据的分布和特性,从而更快地找到最优解、提升训练速度。 Ω 和 ω_t 具体计算公式如下所示:

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega_t})^\theta \quad (10)$$

$$\omega_t = \begin{cases} \frac{|\omega - \omega^{\text{gt}}|}{\max(\omega, \omega^{\text{gt}})}, & t = w \\ \frac{|h - h^{\text{gt}}|}{\max(h, h^{\text{gt}})}, & t = h \end{cases} \quad (11)$$

式中: w 和 w^{gt} 分别为预测框和真实框的宽度; h 和 h^{gt} 分别为预测框和真实框的高度。

3 模型验证

3.1 实验环境

本次实验基于 Windows 10 操作系统开展,构建的实验环境由硬件配置和软件环境两个部分组成。在硬件配置方面,采用 Intel(R) Core(TM) i9-9900K 型号 CPU、NVIDIA GeForce RTX 2080Ti 型号 GPU,搭配 32 G 内存;软件环境方面,依托 Anaconda 3 进行环境管理,基于 PyTorch2.0.1 深度学习框架实现模型训练流程。

3.2 模型参数优化

YOLOv5 模型提供了一种超参数优化的方法,即超参数进化^[24]。经超参数优化后的模型,在实际应用中通常能够表现出更好的性能,不仅可以提高模型的准确性和泛化能力,还可以通过降低模型的复杂度和计算成本,实现其轻量化。超参数进化的内在逻辑是利用遗传算法实现超参数优化。在每一次的迭代过程中,基于所有前代的最佳组合产生新的后代,选择更加适合改进后模型的超参数。本次实验中,适应度设置为精确率(Precision)占比 15%,召回率(Recall)占比 15%,平均检测精度(Mean average precision@IoU=0.5, mAP@0.5)占比 70%。最后,进行了 300 次训练迭代,得到的最优超参数如表 1 所示。

3.3 模型评价

3.3.1 模型评价指标

模型评估指标采用精确率、召回率、平均检测精度(mAP@0.5)以及 F_1 表示检测的准确性;采

表 1 超参数优化结果
Table 1 Results of hyperparameter optimization

超参数	数值	超参数	数值
初始学习率	0.012 40	明度增益	0.375 0
学习率因子	0.011 70	旋转角度/(°)	0.000 0
动量	0.980 00	平移幅度	0.090 1
权重衰减	0.000 48	缩放幅度	0.615 0
预热轮次	4.080 00	剪切幅度	0.000 0
预热动量	0.711 00	透视变换	0.000 0
预热偏置学习率	0.108 00	上下翻转概率	0.000 0
边界框损失权重	0.048 30	左右翻转概率	0.500 0
类别损失权重	0.378 00	马赛克增强概率	0.825 0
类别损失权重因子	1.020 00	混合增强概率	0.000 0
目标存在损失权重	0.976 00	复制粘贴增强概率	0.000 0
目标存在损失权重因子	1.070 00	锚框尺度系数	3.690 0
IoU 阈值(训练)	0.200 00	色调增益	0.012 4
锚框匹配阈值因子	2.920 00	饱和度增益	0.792 0
Focal Loss 伽马值	0.000 00		

用参数量、帧率(Frames per second,FPS)表示检测的速度^[26]。精确率和召回率的计算公式如下所示:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (12)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (13)$$

式中:TP表示预测出的为正例,标签值也为正例,预测正确;FN表示预测出的为负例,标签值为正例,预测错误;FP表示预测出的为正例,标签值为负例,预测错误;TN表示预测出的为负例,标签值为负例,预测正确。

F_1 分数以及mAP@0.5的计算如下所示:

$$F_1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^n \text{AP}_i \quad (15)$$

$$\text{AP} = \sum_{i=1}^{k-1} (r_{i+1} - v) \text{P}_{\text{inter}}(r_i + 1) \quad (16)$$

式中: $r_1, r_2, \dots, r_k$ 为按升序排列的Precison插值段第一个插值处对应的Recall值;mAP为所有类别AP的平均值。

假设有 K 个类别,每个类别都有一个对应的 AP 值($\text{AP}_1, \text{AP}_2, \dots, \text{AP}_K$)。

3.3.2 模型检测精度评价

对于本文构建的数据集,在 YOLOv5s 模型的基础上,依次集成了 CBAM 注意力机制、FasterNet 网络结构以及 SIoU 损失函数模块。消融实

验在精确率、召回率、mAP@0.5 和 F_1 等指标上的表现数据如表 2 所示。

在引入 CBAM 注意力模块后,算法的精确率、召回率、平均检测精度和 F_1 分别提升了 79.7%、67.5%、70.5% 和 73.1%,展现了全面的性能增强。随后,通过引入 FasterNet 网络结构,尽管 Recall 值有所下降,导致 Precision 与 Recall 之间的差距拉大,但 Precision 和 mAP@0.5 指标仍然实现了稳步增长,分别提升了 0.9% 和 0.6%。最终,通过整合 SIOU 模块,模型的精确率、召回率、平均检测精度和 F_1 分别稳定在 81.2%、68.6%、71.5% 和 74.4%,相较于初始模型,分别提升了 3.1%、1.6%、1.7% 和 2.3%。经过这些改进,增强了桥梁缺陷检测模型的性能,展现了其卓越的检测能力。

表 2 改进 YOLOv5 算法消融实验结果分析
Table 2 Analysis of the results of the ablation experiments on the improved YOLOv5 algorithm

CBAM	FasterNet	SIoU	精确率	召回率	平均检测精度	F_1 分数
			0.782	0.670	0.699	0.722
✓			0.797	0.675	0.705	0.731
✓	✓		0.806	0.660	0.711	0.726
✓	✓	✓	0.812	0.686	0.715	0.744

3.3.3 模型检测速度评价

为了全面评估改进后 YOLOv5 模型的轻量化程度和检测速度,本文设计了对比实验,选取 YOLOv5 系列中的 YOLOv5n、YOLOv5s 以及 YOLOv8s 作为基准,与经过优化的 YOLOv5 模型进行比较,结果如表 3 所示。实验结果表明,相较于 YOLOv5s,YOLOv5n 虽然参数数量显著减少,却牺牲了精度。相反,YOLOv8s 虽然成功提升了运算速度,但未能维持原有的精度水平。而改进的 YOLOv5 模型在保持原有功能的基础上,实现了显著的轻量化和性能提升。具体而言,该模型成功地将参数量从原始的 7 027 720 减少至 6 357 760,缩减了 9.53%。更为重要的是,该改进并未以牺牲精度为代价,反而进一步优化了模型的各项精度指标。

3.4 对比验证

为验证本文缺陷检测模型的先进性和效能,设计了一系列对比实验,将其与经典目标检测算法进行比较。这些算法包括但不限于 Faster R-

表 3 骨干网络对比结果

Table 3 Comparison results of backbone networks

模型	精确率	召回率	平均检测精度	参数量	帧率 (帧·s ⁻¹)
YOLOv5n	0.683	0.634	0.651	205 728 8	34.44
YOLOv5s	0.781	0.670	0.698	702 772 0	39.84
YOLOv5s	0.731	0.661	0.683	605 728 8	53.01
改进后的 YOLOv5	0.812	0.686	0.715	635 776 0	52.08

CNN、SSD、YOLOv5 以及 YOLOv8。比较基准涵盖了 mAP@0.5、Precision、Recall 以及 FPS 共 4 项关键性能指标,以全面评估各模型在缺陷检测任务上的表现。对比数据汇总于表 4。实验结果显示,相较于原有模型,改进后的 YOLOv5 模型的 4 项检测指标分别提升了 2.00%、3.97%、2.39% 和 30.72%;对比其他经典目标检测算法,在综合检测性能上表现更优。

表 4 与其他经典目标检测对比结果

Table 4 Comparison results of backbone networks

模型	平均检测精度	精确率	召回率	帧率/ (帧·s ⁻¹)
Faster R-CNN	0.507	0.748	0.531	13.62
SSD	0.512	0.676	0.542	35.62
YOLOv5s	0.698	0.781	0.670	39.84
YOLOv8s	0.683	0.731	0.661	53.01
YOLOv11	0.696	0.793	0.686	55.24
改进后的 YOLOv5	0.715	0.812	0.686	52.08

从表 3 和表 4 可以看出,本文方法对桥梁表面缺陷的平均检测精度高于其他目标检测算法。其中 Faster RCNN、SSD 和 YOLOv5 在各项指标上均不如改进后的 YOLOv5 模型,YOLOv8 虽然在检测速度(FPS)上略高于改进的 YOLOv5 模型,但是在平均检测精度、精确率和召回率方面效果并不如改进后的 YOLOv5 模型。进一步说明本文轻量化检测模型在桥梁缺陷检测任务的检测精度以及运算效率方面均有一定程度的提高。通过对比分析,证明了本文模型具有较高的可靠性。

4 结 论

(1)使用新的混合架构,将部分卷积和 CBAM 注意力机制融合,减少了模型整体参数量并降低了模型复杂性,获取到更大的感受野;采用 SIOU 损失函数替换原有的 GIoU 损失函数,从缺陷类型中提取更多特征信息并优化计算;通过自适应地调整超参数配置,使模型在训练过程中展现出更强的适应性和泛化能力,从而提升其检测

性能。改进后的缺陷检测模型精确率提升了 3.1%,召回率提升了 1.6%,平均检测精度和 F_1 也都有不同程度的提高,充分验证了模型在桥梁缺陷检测领域的有效性。

(2)经过优化的 YOLOv5 模型相较于改进前,不仅在多项精度指标上显著提升,而且成功缩减了模型参数量并加速了检测过程。具体而言,优化后的模型参数量减至 6 357 760,下降了 9.53%;同时,帧率(FPS)跃升至 52.08 帧/s,性能提升了 30.72%,为模型的实际应用打下了坚实基础。

(3)本文所依托的自建桥梁缺陷数据集尚存优化空间,主要体现为样本总量有限,不断增加样本量会出现缺陷类别与实例间的不均衡现象,易导致长尾效应,影响模型对少数类别缺陷情况的有效识别能力。未来工作将不断平衡数据集结构,缓解长尾效应,提升桥梁缺陷检测模型的泛化能力和整体检测性能。

参考文献:

- [1] 丁威,夏哲,舒江鹏,等. 基于负压吸附爬壁机器人和 Transformer 的混凝土桥塔裂缝识别检测[J]. 中国公路学报, 2024, 37(2): 53-64.
Ding Wei, Xia Zhe, Shu Jiang-peng, et al. Recognition and detection of concrete bridge tower cracks using a negative pressure adhesion wall-climbing robot and Transformer[J]. China Journal of Highway and Transport, 2024, 37(2): 53-64.
- [2] 刘凯,李家坡,邓智允,等. 无人机桥梁检测技术的经济效益分析[J]. 南昌工程学院学报, 2018(3): 51-53,80.
Liu Kai, Li Jia-po, Deng Zhi-yun, et al. Benefit analysis of unmanned aerial vehicle bridge detection technology[J]. Journal of Nanchang Institute of Technology, 2018(3): 51-53,80.
- [3] 邹金欢. 无人机在输电线路巡检中的应用及效益分析[J]. 中国战略新兴产业, 2023(36): 153-155.
Zou Jin-huan. Application and benefit analysis of drones in transmission line inspection[J]. China Strategic Emerging Industry, 2023(36): 153-155.
- [4] Oppenheim D, Shani G, Erlich O, et al. Using deep learning for image-based potato tuber disease detection[J]. Phytopathology, 2019, 109(6): 1083-1087.
- [5] Wang J X, Su Y H, Yao J H, et al. Apple rapid recognition and processing method based on an improved version of YOLOv5[J]. Ecological Informatics,

- 2023, 77: No. 102196.
- [6] 贾雪莹, 赵春江, 周娟, 等. 基于改进YOLOv7模型的柑橘表面缺陷在线检测[J]. 农业工程学报, 2023, 39(23): 142-151.
- Jia Xue-ying, Zhao Chun-jiang, Zhou Juan, et al. Online detection of citrus surface defects using improved YOLOv7 modeling[J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(23): 142-151.
- [7] 王庞伟. 基于金字塔特征融合的二阶段三维点云车辆检测[J]. 交通运输系统工程与信息, 2022, 22(5): 107-116.
- Wang Pang-wei. Pyramid-feature-fusion-based two-stage vehicle detection via 3D point cloud[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(5): 107-116.
- [8] 张河山, 范梦伟, 谭鑫, 等. 基于改进YOLOX的无人机航拍图像密集小目标车辆检测[J]. 吉林大学学报: 工学版, 2025, 55(4): 1307-1318.
- Zhang He-shan, Fan Meng-wei, Tan Xin, et al. Dense small target vehicle detection in UAV aerial images based on improved YOLOX[J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(4): 1307-1318.
- [9] Yang Li-na, Chen Gang, Ci Wen-yan. Multiclass objects detection algorithm using DarkNet-53 and DenseNet for intelligent vehicles[J]. EURASIP Journal on Advances in Signal Processing, 2023, 2023(1): 1-18.
- [10] Cao F, Xing B, Luo J C, et al. An efficient object detection algorithm based on improved YOLOv5 for High-Spatial-Resolution remote sensing images[J]. Remote Sensing, 2023, 15(15): No. 3755.
- [11] 许晓阳, 高重阳. 改进YOLOv7-tiny的轻量级红外车辆目标检测算法[J]. 计算机工程与应用, 2024, 60(1): 74-83.
- Xu Xiao-yang, Gao Chong-yang. Improved YOLOv7-tiny lightweight infrared vehicle target detection algorithm[J]. Computer Engineering and Applications, 2024, 60(1): 74-83.
- [12] 彭卫兵, 张明见, 全柳萌, 等. 基于改进Mask R-CNN的钢桥多缺陷智能识别[J]. 中国公路学报, 2024, 37(2): 100-109.
- Peng Wei-bing, Zhang Ming-jian, Quan Liu-meng, et al. Intelligent recognition of multiple diseases in steel bridges based on improved Mask R-CNN[J]. China Journal of Highway and Transport, 2024, 37(2): 100-109.
- [13] 陈昭俊. 二阶段锚框和类均衡损失的遥感图像目标检测[J]. 图学学报, 2023, 44(2): 249-259.
- Chen Zhao-jun. Object detection in remote sensing image based on two-stage anchor and class balanced loss[J]. Journal of Graphics, 2023, 44(2): 249-259.
- [14] 蒋燕芳. 基于图像处理与深度学习的RC桥梁表观病害识别[D]. 重庆: 重庆大学土木工程学院, 2019.
- Jiang Yan-fang. Identification of apparent defects in RC bridge with image processing and deep learning [D]. Chongqing: College of Civil Engineering, Chongqing University, 2019.
- [15] Zeng G, Wu Z Z, Xu L P, et al. Efficient vision Transformer YOLOv5 for accurate and fast traffic sign detection[J]. Electronics, 2024, 13(5): No. 880.
- [16] 徐鑫. 基于YOLOv5的医学图像病变区域检测研究与应用[D]. 镇江: 江苏大学计算机科学与通信工程学院, 2023.
- Xu Xin. Research and application of medical image lesion region detection based on YOLOv5[D]. Zhenjiang: School of Computer Science and Communication Engineering, Jiangsu University, 2023.
- [17] 钟源, 袁家政, 李鸿天, 等. 改进YOLOv5的智慧课堂人脸检测算法[J]. 计算机工程与应用, 2024, 60(11): 251-257.
- Zhong Yuan, Yuan Jia-zheng, Li Hong-tian, et al. Intelligent classroom face detection algorithm with improved YOLOv5[J]. Computer Engineering and Applications, 2024, 60(11): 251-257.
- [18] Rejin V, Sambath M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS), Chennai, India, 2024: 1-6.
- [19] Chen J R, Kao S H, He H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, Canada, 2023: 12021-12031.
- [20] Chen J, He T, Zhuo W, et al. TVConv: efficient translation variant convolution for layout-aware visual processing [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, USA, 2022: 12538-12548.
- [21] 张楠楠, 张晓, 白铁成, 等. 基于CBAM-YOLOv7的自然环境下棉叶病虫害识别方法[J]. 农业机械学报, 2023, 54(201): 239-244.
- Zhang Nan-nan, Zhang Xiao, Bai Tie-cheng, et al. Pest and disease identification method for cotton

- leaves in natural environments based on CBAM-YOLOv7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(201): 239-244.
- [22] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[J]. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2018, 11211: 3-19.
- [23] Hamid R, Nathan T, Junyoung G, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 658-666.
- [24] Gevorgyan Z. SIOU Loss: more powerful learning for bounding box regression[DB/OL]. [2025-06-05]. <https://arxiv.org/abs/2205.12740>.
- [25] 王一旭, 肖小玲, 王鹏飞, 等. 改进 YOLOv5s 的小目标烟雾火焰检测算法[J]. 计算机工程与应用, 2023, 59(1): 72-81.
- Wang Yi-xu, Xiao Xiao-ling, Wang Peng-fei, et al. Improved YOLOv5s small target smoke and fire detection algorithm[J]. Computer Engineering and Applications, 2023, 59(1): 72-81.
- [26] 孙长亮, 何峻, 肖怀铁. 基于 ROC 曲线的目标识别性能评估方法[J]. 雷达科学与技术, 2007, 5(1): 17-21.
- Sun Chang-liang, He Jun, Xiao Huai-tie. A new performance evaluation method based on ROC curve[J]. Radar Science and Technology, 2007, 5(1): 17-21.