

DOI:10.19651/j.cnki.emt.2415684

基于 YOLOv8 的煤矿用钢丝绳损伤检测算法^{*}李志星¹ 杨啸龙¹ 李天昊¹ 王宁宁²

(1. 北京建筑大学机电与车辆工程学院 北京 100000; 2. 洛阳理工学院智能制造学院 洛阳 471000)

摘 要: 煤矿用钢丝绳在矿井作业中发挥着重要的应用价值,其可靠性直接关系到矿山运转效率以及工作人员的生命安全。针对现有钢丝绳表面缺陷检测精度较低、检测效率不足的问题,本文提出一种改进型 YOLOv8 检测算法 YOLO_BF,首先在骨干网路中引入改进型双层链路注意力机制(BiFormer)加强模型对图像的分析能力和信息融合能力,显著提高模型的精度。其次嵌入重复加权双向特征金字塔网路(BiFPN)提高网络缺陷特征提取能力,并在此基础上使用 WIoU 提高模型收敛速度,最后使用幻影卷积(GhostConv)替换传统卷积实现模型轻量化。相比原始基础网络 YOLOv8n,本文所设计网络准确率、召回率和平均精度分别提升 2.3%、3.3%、5.2%,更符合钢丝绳损伤检测的实际应用要求。

关键词: 钢丝绳;缺陷检测;YOLO;注意力机制;损失函数

中图分类号: TN919.8;TP391.4 **文献标识码:** A **国家标准学科分类代码:** 460.4030

YOLOv8-based surface damage detection of mine wire rope

Li Zhixing¹ Yang Xiaolong¹ Li Tianhao¹ Wang Ningning²

(1. School of Mechanical, Electrical and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100000, China; 2. School of Intelligent Manufacturing, Luoyang Institute of Science and Technology, Luoyang 471000, China)

Abstract: The wire rope used in coal mine plays an important application value in mine operation, and its reliability is directly related to the operation efficiency of the mine and the life safety of the staff. Aiming at the problems of low detection accuracy and insufficient detection efficiency of existing wire rope surface defects. This paper proposes an improved YOLOv8 detection algorithm YOLO_BF. Firstly, an improved double-layer link attention mechanism (BiFormer) is introduced into the backbone network to enhance the model's ability to analyze images and information fusion, which significantly improves the accuracy of the model. Secondly, the repeated weighted bidirectional feature pyramid network (BiFPN) is embedded to improve the ability of network defect feature extraction. On this basis, WIoU is used to improve the convergence speed of the model. Finally, GhostConv is used to replace the traditional convolution to realize the lightweight of the model. Compared with the original basic network YOLOv8n, the accuracy, recall and average accuracy are increased by 2.3%, 3.3% and 5.2% respectively. It is more in line with the practical application requirements of wire rope damage detection.

Keywords: wire rope;defect detection;YOLO;attention mechanism;loss function

0 引 言

煤矿钢丝绳在矿井作业中具有重要作用,不仅关系到生产效率,还直接影响到职工的安全和设备的正常运行。因矿井工作环境恶劣以及钢丝绳长期处于高强度受力状态、频繁使用和摩擦、环境腐蚀,钢丝绳出现磨损、断丝、腐蚀等表面损伤是不可避免的^[1]。目前钢丝绳缺陷检测主要

通过人工目测法和定期更换法^[2],其效率极低还会浪费大量钢材,为解决这一问题,国内外专家做出了许多相关方面的研究,超声波检测法、电磁检测法、声波检测法、x射线检测法等方法^[3-6],主要基于物理传感器,虽然相较于人工提高了识别效率,但仍然会存在难以区分损伤类别、易受外界干扰等问题。

近年来兴起的机器视觉飞速发展为人们提供了图像视

收稿日期:2024-03-23

^{*} 基金项目:北京市属高校基本科研业务费项目(X21053)、河南省高等学校重点科研项目(23A460020)、河南省自然科学基金(242300420044)、北京建筑大学研究生创新项目(PG2024136)资助

频检测法,Krizhevsky 等^[7]提出了 AlexNet 模型引领了深度学习革新的浪潮,机器视觉技术开始应用于钢丝绳的表面损伤检测中,如 Wackwer 等^[8]提出将对象几何形状与观察到的绳索外观联系起来,构建了一个概率外观模型从而识别断丝。随着卷积神经网络(convolutional neural networks, CNN)的发展,各国学者提出了众多的网络模型,用于优化网络结构,减轻计算负担,增强模型的学习能力,如区域卷积神经网络(region convolutional neural networks, RCNN)、FastRCNN 模型、GoogLeNet 模型、残差网络(residual network, ResNet)等^[9-12],如陈荣信等^[13]基于残差网络实现了钢丝绳的图像定量识别。以上都是双阶段检测模型,这种模型的检测速度通常较慢,因此在工业领域的应用存在一定的难度。2016 年,SSD(single shot multibox detector, SSD)网络^[14]单阶段检测算法推出,同年 Redmom 等^[15]提出了单阶段检测模型 YOLOv1,经过在此基础上的不断迭代推出 YOLOv8,此类检测方法虽在检测精度上略逊于双阶段检测方法,但检测速度更快、计算量小,满足工业生产中的实时性要求。如张乾闯等^[16]改进 YOLO 网络实现对光纤环绕制缺陷检测,钱承山等^[17]提出一种基于改进 YOLOv5 的山火检测识别方法的研究,有效的通过检测高温点及时预防火灾发生。YOLO 算法也广泛用于钢丝绳表面损伤检测当中,如高嘉等^[18]基于 YOLOv5 改进网络的曳引钢丝绳缺陷检测网络算法,王红

尧等^[19]采用改进 YOLOv5 算法的快速自适应加权中值滤波图像预处理技术提高了钢丝绳损伤图像的识别准确率。

矿井作业环境中由于条件限制无法使用大型设备进行检测作业,嵌入式设备成为了进行检测作业的首选工具。为此本文提出了一种创新的钢丝绳表面损伤检测算法 YOLO_BF,该算法基于 YOLOv8 进行优化,专门针对嵌入式设备的应用需求,在不增加模型复杂度的情况下,实现了对钢丝绳表面缺陷检测精度和效率的显著提升,该算法将传统的空间金字塔池化算法(spatial pyramid pooling with features, SPPF)中融入 BiFormer 双层链路注意力机制,加强模型对图像的分析能力和信息融合能力,其次通过其次嵌入重复加权双向特征金字塔网路 BiFPN,采用加权的特征融合机制,提高网络缺陷特征提取能力,并在此基础上使用 WIoU 提高模型收敛速度,最后使用幻影卷积 GhostConv 替换传统卷积实现模型轻量化。实验表明,该方法减少了煤矿用钢丝绳因环境复杂而产生的漏检,提高了检测效率和精度,为后续的生产活动提供了一定的参考价值。

1 YOLOv8 算法

YOLOv8 网络结构主要由 4 大部分构成:输入端、骨干网络(backbone)、颈部网络(neck)和检测输出端(head)结构如图 1 所示。

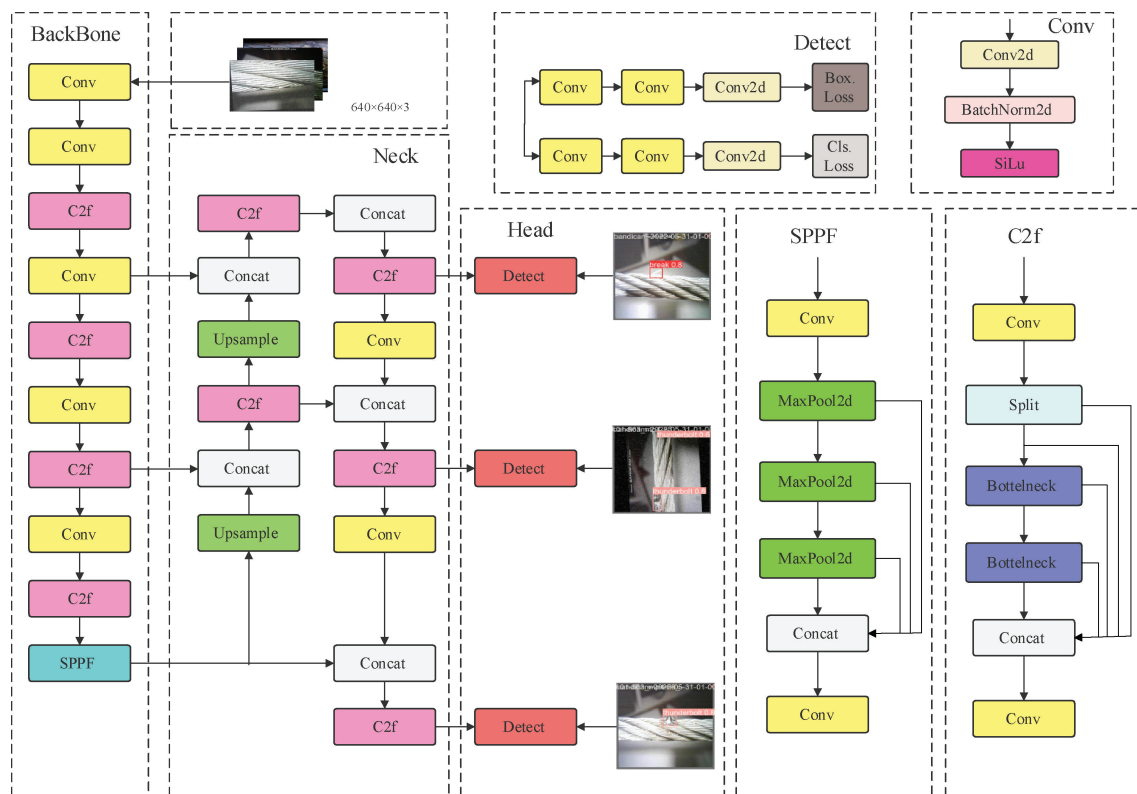


图 1 YOLOv8 网络结构

输入端将钢丝绳图像送入网络。Backbone 部分采用 Darknet53 结构,其中包括卷积单元 Conv、实现局部特征与全局特征融合模块 SPPF,与结合了 YOLOv5 中 C3 模块和 YOLOv7 中高效聚合网络的特点的 C2f 模块。Neck 网络部分采用 CSPNet 设计的 CSP2 结构,从而加强了网络特征融合能力,头部网络主要通过路径聚合网络和预测头实现钢丝绳的特征融合和目标检测。

2 改进的 YOLOv8 模型

本文主要用于矿井钢丝绳的损伤检测工作,该任务面临几个关键挑战:首先,矿井内光线非常暗淡,这大大增加了检测过程中的漏检风险;其次,矿井环境中充斥着大量

粉尘,背景存在大量干扰;最后,考虑到检测模型需在嵌入式设备上运行,对网络的参数量提出了限制,需确保算法的可以满足设备流畅运行需求。将 YOLOv8 直接应用于实际生产环境中时,由于其本身特征识别模块无法适用于矿井复杂的工作环境,会出现严重的漏检和误检问题。因此本文对原有 YOLOv8 网络结构进行改进,结构如图 2 所示,首先在骨干网路中的 SPFF 模块后引入改进型双层链路注意力机制 BiFormer 加强模型对图像的分析能力和信息融合能力,显著提高模型的精度。其次嵌入重复加权双向特征金字塔网路 BiFPN 提高网络缺陷特征提取能力,并在此基础上使用 WIoU 提高模型收敛速度,最后使用幻影卷积 GhostConv 替换传统卷积以减少模型复杂度。

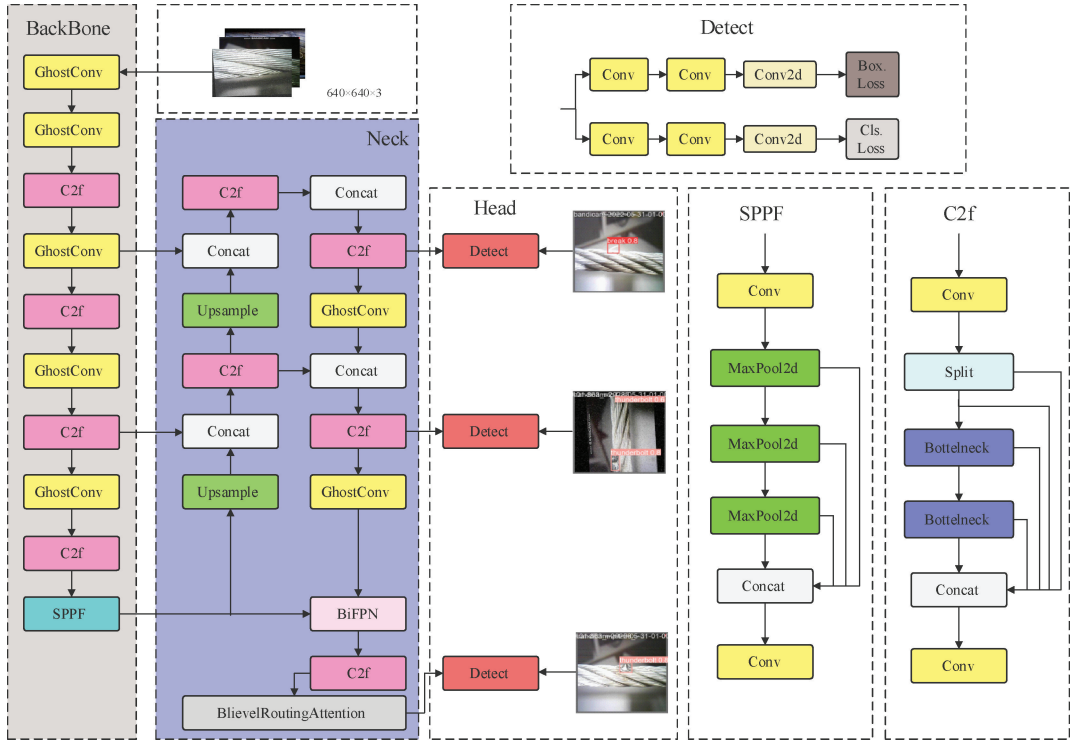


图 2 改进 YOLOv8 网络模型

2.1 GhostConv 模块

本文采用 GhostConv 模块实现对算法参数数量的控制,其结构如图 3 所示。GhostConv 模块卷积结构通过分解常规卷积操作为两个部分来减少特征冗余和参数量。该模块采用点对点卷积操作来产生一些特征图,利用这些已生成的特征图来构建余下的特征映射。通过这种方法, GhostConv 卷积在不降低模型性能的前提下大幅度减少了参数和计算量,设输入特征的高、宽和通道数为 h 、 w 和 c ,输出特征的高度和宽度为 H 和 W ,卷积核数量为 n ,卷积核大小为 k ,线性变换卷积核大小为 d ,变换数量为 s 。 r_s 和 r_c 分别表示普通卷积和 GhostConv 卷积的计算量和参数量之比,其中计算公式如式(1)~(2)所示。

$$r_s = \frac{h \times w \times c \times H \times W \times n}{\frac{n}{s} \times H \times W \times k \times k \times c + (s-1) \times \frac{n}{s} \times H \times W \times d \times d} = \frac{c \times k \times k}{\frac{1}{s} \times c \times k \times k + \frac{(s-1)}{s} \times d \times d} \approx s \quad (1)$$

$$r_c = \frac{n \times c \times k \times k}{\frac{n}{s} \times c \times k \times k + (s-1) \times \frac{n}{s} \times d \times d} \approx \frac{s \times c}{s + c - 1} \approx s \quad (2)$$

由式(1)~(2)可以看出在相同的操作下, GhostConv 是普通卷积计算量的 $1/s$,因此,通过在主干网络中用 GhostConv 替换传统的卷积操作(Conv),可以显著降低算法模型的复杂性。 GhostConv 设计旨在通过生成更多的特征图而无需增加额外的计算成本,来优化卷积层的计算效

率。这种替换策略有效减少了模型对计算资源的需求,同时保持并提高了模型处理数据的能力。

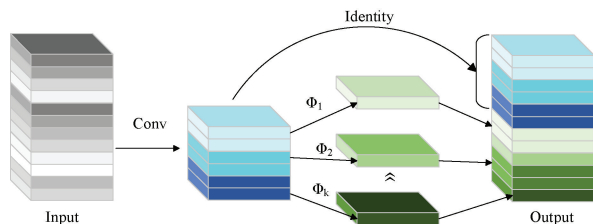


图 3 GhostConv 卷积

2.2 BiFPN 特征融合网络

钢丝绳的初始损伤通常是极微小且不易察觉的,但如果能在其损伤初期及时发现,就能显著降低潜在隐患的发生率。YOLOv8 中,使用了路径聚合网络(PANet)。PANet 同时具有自上而下和自下而上两种路径,因此,它可以融合顶层和底层的特征信息。虽然这种方法可以提高检测精度,但容易遗漏微小目标物体。为了解决这个问题,本文将 PANet 替换为 BiFPN^[20]。PANet 和 BiFPN 的结构如图 4 所示。PANet 在 FPN 的基础上引入了一条反向路径,以传递遗失的位置信息,如图 4(a)所示。BiFPN 是一种加权双向特征金字塔网络,如图 4(b)所示。它在 PANet 的基础上简化了网络结构,删除了单一输入节点,以确保不丢失重要信息。同时,当输入节点和输出节点位于同一层时,通过增加额外的边来集成额外的特征。更重要的是, BiFPN 采用加权的特征融合机制,为数据经过的每条路径分配合理的权重,随着模型的训练深入,这一动态权重调整机制允许 BiFPN 逐渐优化其特征融合策略,从而能够更加准确地挖掘和整合来自不同层级的、有益的信息。然后利用学习到的特征不断更新权重,以获得更有价值的信息。

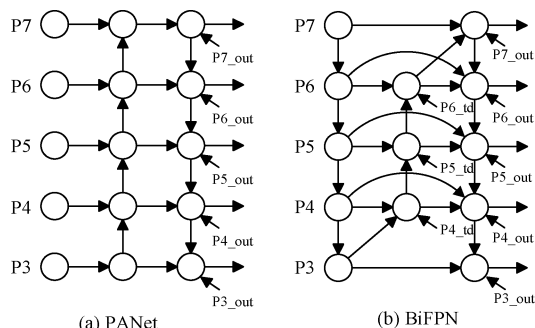


图 4 PANet、BiFPN 模型结构图

2.3 BiFormer 注意力机制

为实现了对煤矿工作中昏暗环境环境中钢丝绳特征的精细化关注。YOLOv8 的模型架构中,通过在 Backbone 和 Neck 之间融合了一种名为 BiFormer 的动态稀疏注意力模块,这个自适应查询机制的引入使得模型能够集中处理相关的特征而非干扰信息,这不仅增强了模型性能,也提升了计算效率。YOLO_BF 模型在空间金字塔特征融合流程 SPFF 之后集成了 BiFormer 模块,有效地消减了不必要的背景信息,集中精力于钢丝绳损伤表面的检测区域。

BiFormer 的架构围绕着 BRA 作为关键的构建模块,并设计了一个 4 层金字塔的布局如图 5(a)所示。第 1 阶段,采用了重叠的图像块嵌入技术;接着在第 2~4 阶段,进行图像合并模块的使用,这一过程中降低了图像分辨率并提高了通道容量。最后通过串接的 BiFormer 模块对输入数据的特征进行转换处理。BiFormer 的整体架构,如图 5(b)所示,每个 BiFormer 块的开端通过 3×3 深度可分离卷积来隐式地编码位置信息。随后, BRA 模块在捕获双向相对注意力,最后通过双层感知器(multilayer perceptron, MLP)进行关系模型构建以及位置信息的嵌入。

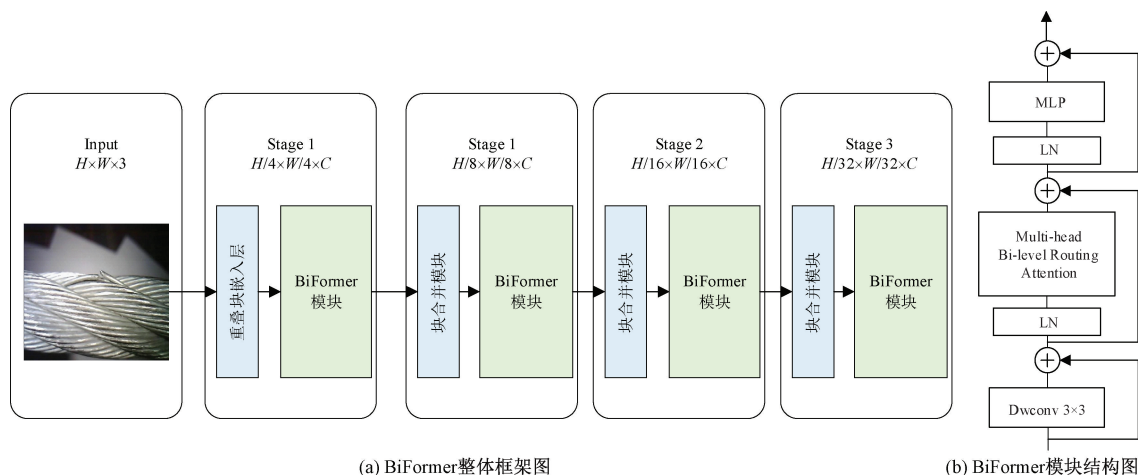


图 5 BiFormer 结构图

2.4 损失函数优化

为了降低煤矿作业中存在的强背景干扰的影响,本文

使用 WIoU 替换了 YOLO 算法传统的 CIoU,在 CIoU 损失函数中,所有的目标被同等对待,很少考虑数据集本身

标注示例的质量。而 WIoU 损失函数旨在解决目标检测任务中的类别不平衡和目标大小不平衡的问题。这使它在面对不同几何因素的目标时具有更好的性能,并提高了模型的泛化性能。WIoU 损失函数表达式为如式(3)~(5)所示。

$$L_{WIoU} = \frac{\beta}{\delta \alpha^{\beta-\delta}} R_{WIoU} L_{IoU}$$

(3)

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right)$$

(4)

$$L_{IoU} = 1 - IoU$$

(5)

式中:为梯度增益 r 与 β 的映射关系由超参数 α 与 δ 确定。 W_g 和 H_g 是最小包围框的尺寸, (x, y) 和 (x_{gt}, y_{gt}) 分别为锚框和目标框中心点的坐标, β 描述锚框质量的离群度其计算公式如式(6)所示。

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty)$$

(6)

式中: $\overline{L_{IoU}}$ 为动量 m 的滑动平均值, 动量 m 的计算公式如式(7)所示, 动量 m 用于延迟 $\overline{L_{IoU}}$ 接近真实值 $L_{IoU} - real$ 如式(8)所示。

$$m = 1 - \sqrt[n]{0.5}, tn > 7\ 000$$

(7)

$$\overline{L_{IoU}} = 0.5(1 + \overline{L_{IoU} - real})$$

(8)

3 实验分析与讨论

3.1 实验数据集

为验证所提改进策略的功效, 本研究引入了 RoboflowDBTT 数据集, 并通过数据增强技术生成了一个新的钢丝绳缺陷数据集 Wear Damage。该数据集涵盖了 3 类钢缆缺陷: 断裂、磨损和腐蚀, 共计 3 516 张图片。这些数据被分为训练集、验证集和测试集, 比例分别是 70%、20% 和 10%。训练集包含 2 461 张图片, 验证集包含 705 张图片, 测试集包含 349 张图片。训练集的目的是优化网络参数, 以实现最小化损失函数, 而验证集则用于评估模型对钢缆表面损伤识别的准确性。数据集中包含的 3 种损伤类型如图 6 所示。

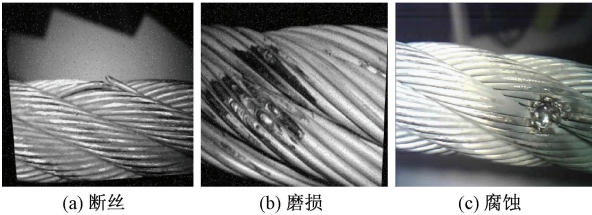


图 6 数据集中 3 种损坏类型

3.2 实验配置

本文实验环境如表 1 所示, 训练模型的基本参数为进行 300 次迭代, 每批次输入数据量大小为 16, 将输入图像统一变换为 640×640 大小并归一化, 采用随机梯度(SGD)下降优化器, 采用线性学习率调度策略, 初始学习率为

0.01, 最终学习率为 0.000 1。warm epochs 为 3.0, 动量参数为 0.8 用于加速训练过程, 权重衰减系数为 0.000 5。

表 1 实验环境

名称	环境参数
操作系统	Windows 10 64 位
CPU	Intel(R) Xeon(R) Platinum 8 352 V
GPU	RTX 4 090(24 GB)
内存	90 GB
Python	3.10(ubuntu22.04)
Pythorch	2.10
Cuda	12.1

3.3 评价指标

钢丝绳表面损伤检测属于目标检测领域, 目前目标检测的标价模型计算效率和存储效率的指标有参数量和千亿次浮点运算(giga floating-point operations per second, GFLOPs), 评价模型精确度的指标主要有精确率(precision)其计算公式如式(9)所示, 精确率的分子为真正例(true positive, TP), 即正确预测为正例的数量; 分母则是 TP 加上假正例(false positive, FP), 随着精确率的提升, FP 的数量减少, 意味着将非目标类别误判为目标类别的情况较少, 从而提高了预测正例的纯度。

$$Precision = \frac{TP}{TP + FP}$$

(9)

召回率(recall)计算公式如式(10)所示, 其专注于准确识别正负例和实际的正例之间的关系。随着召回率的增加, 假负例(false negative, FN)的数目降低, 表明把正例错判为负例的情况变少, 意味着实际正例被成功识别的比例更高。因此, 较高的召回率反映了更低的漏检率。

$$Recall = \frac{TP}{TP + FN}$$

(10)

平均精度均值(mean average precision, mAP)计算公式如式(11)所示, 是将所有类别的平均精度(average precision, AP)进行汇总取平均后得到的指标。AP 衡量的是单个类别预测准确性的标准, 而 mAP 综合了所有类别的 AP, 从而评估模型整体的预测性能。mAP 值的提升意味着精确率-召回率(PR)曲线与坐标轴之间的区域面积增加。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

(11)

3.4 损失函数对比

为提升目标检测模型的性能, 本研究深入探讨了在 YOLOv8 架构下, 不同边界框回归损失函数对模型效能的影响。原始的 YOLOv8 模型采用了 CIoU 损失函数, 该函数在模型训练期间展示了良好的拟合性能。然而, 预测框的宽高比作为相对量进行计算时, 其固有的不确定性, 加

之对于高低质量锚框的不同影响,可能对回归损失的优化造成障碍。针对此问题,本研究引入YOLO_BF,通过比较WIoU、CIoU、EIoU以及SIoU等不同损失函数对模型收敛性的影响,以期找到更优的损失函数方案。

通过详细的实验对比实验结果如图7所示,结果显示在不同损失函数下,模型的收敛速度和最终损失值表现出显著差异。具体来说,EIoU损失函数下的模型收敛速度最慢,且最终损失值最高,而SIoU和CIoU在这两个方面的表现略优于EIoU,显示出较快的收敛速度和稍低的损失值。值得注意的是,引入WIoU损失函数后,模型在训练初期的梯度下降速度显著加快,特别是在前20轮迭代中快速达到收敛,其最终损失值也大幅低于其他3种损失函数。进一步的分析表明,采用WIoU损失函数不仅加快了模型的收敛速度,同时也在准确率、召回率和平均精度等关键性能指标上实现了显著提升。

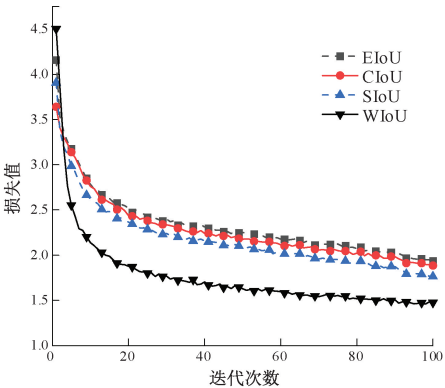


图7 改进损失函数对比

3.5 消融实验

本节采用消融实验验证法对BiFormer模块、BiFPN模块、GhostCov模块以及WIoU损失函数改进在钢丝绳表面损伤识别上的优势,实验结果如表2所示。

表2 消融实验

试验	基线网络	BiFormer	WIoU	BiFPN	GhostConv	Precision/%	Recall/%	mAP/%	Params/M	GFLOPs
1	YOLOv8n	×	×	×	×	78.8	68.3	72.4	3.01	8.1
2	YOLOv8n	✓	×	×	×	79.7	75.8	78.3	3.17	9.5
3	YOLOv8n	×	✓	×	×	79.9	70.4	75.4	3.01	8.1
4	YOLOv8n	×	×	✓	×	75.2	68.3	73.2	3.00	8.0
5	YOLOv8n	×	×	×	✓	78.1	69.2	72.2	2.62	7.5
6	YOLOv8n	✓	✓	×	×	78.5	69.3	73.1	3.02	8.8
7	YOLOv8n	✓	✓	✓	×	73.8	68.5	72.1	3.02	8.8
8	YOLOv8n	✓	✓	✓	✓	81.1	71.7	78.2	2.74	8.0

注:✓为使用该算法;×为不使用该算法。

从表2中可知,融入Biformer注意力机制提高模型平均精度,利用部分卷积改进GhostConv模块后,减小了参数量和模型大小,提高模型推理速度,采用BiFPN特征融合网络增加重复双向跨尺度连接和带权重的特征融合,进一步减小参数量和模型大小。提高模型召回率。利用WIoU损失函数提供合理的梯度增益分配策略。

试验2在YOLOv8n网络中融入Biformer注意力机制后模型精确度、召回率和平均精度都有显著提升,但由于BiFormer模块结构复杂,参数数量和GFLOPs略有增加。试验3替换WIoU损失函数后,模型精确率、召回率、平均精度均有提升,表明WIoU可以提高模型的拟合程度,提高模型识别精度;试验4替换特征融合网路为BiFPN后,模型召回率下降3.5%,但模型在平均精度提高0.8%的基础上参数数量和GFLOPs有所减少,表明BiFPN所采用的加权特征融合策略有效地整合了来自不同层级的多尺度特征,为重要特征赋予更高的权重,优化了特征的表达能力。试验5在YOLOv8n网络中将原来Conv模块替换为GhostConv模块后,模型参数数量下降

0.39,GFLOPs下降了0.6,但模型召回率和平均精度有所下降,其原因在于分解常规卷积操作为两个部分来减少特征冗余,导致召回率和平均精度略有减小。试验6~8在添加BiFormer注意力机制的基础上依次加入了WIoU、BiFPN、GhostConv,最终获得最优的模型检测精确度和泛化能力。与基线网络相比,经过改进后,模型参数数量减小0.27,GFLOPs减小0.1,模型精确率提升2.3%,召回率提升3.3%,平均精度提升5.2%。

3.6 训练结果分析

在经过300次迭代训练之后,优化版模型的性能表现通过以下图表得以展现:图8展示了优化模型的损失变化趋势,而图9则描绘了模型的平均精度(mAP)的变化情况。

通过观察分析,模型在最初的20轮训练中表现出了明显的快速收敛特性。这个阶段之后,尽管训练损失的减少速度有所放慢,但模型的性能仍在持续而稳定地提升,直至训练过程的最终完成。这一现象反映出模型在训练期间展现出了优异的学习效果,成功避免了过拟合和欠拟合的问题。

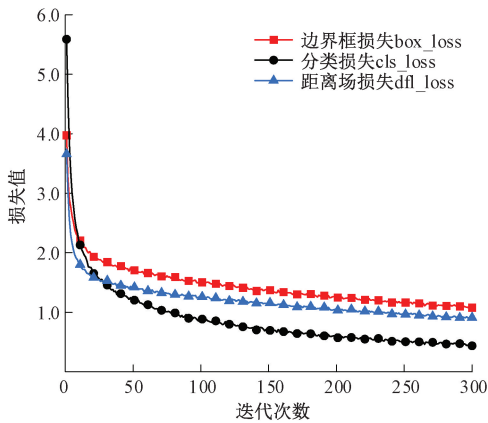


图 8 边界框、分类和距离场损失值迭代图

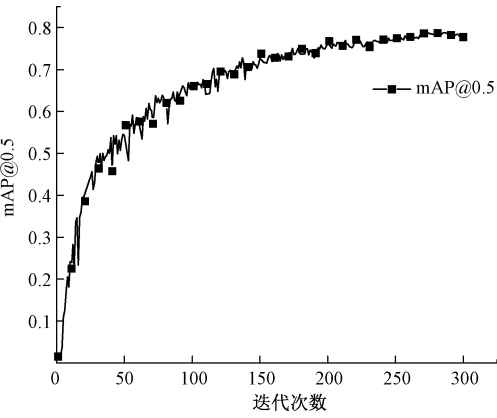


图 9 mAP@0.5 迭代图

3.7 对照实验及分析

为了评估本文提出的改进网络在钢丝绳表面损伤识别任务上的性能,本文使用了多个现有的网络模型进行对比,包括 YOLOv5、YOLOv8 和 RT-DETR-L,并与常用的二阶段目标检测网络 Faster-RCNN 进行性能对比。此外,本文还将 YOLOv8 默认的 Backbone 主干替换成轻量级骨干网络 MobileNetV3^[21]、ShuffleNetV2 和 GhostNet,并对比它们的表现。

对比结果如表 3 所示,由不同模型对比实验可知,虽然 RT-DETR-L 平均精度略高于 YOLO_BF,但由于其是一种结合了 Transformer 架构和 RetinaNet 特性的目标检测模型导致有了更高的计算成本。YOLOv5s、Faster-RCNN 在钢丝绳表面损伤识别上的表现均不如 YOLO_BF 模型,本文网络在保证平均精度的同时,在计算成本和

模型。大小上均有优于其他模型的表现,其中替换骨干的 MobileNetV3-v8、ShuffleNetV2-v5、GhostNet-v5 网络由于其使用大量轻量级卷积且网络深度较浅。在参数量和计算量上略低于改进后网络。但是它们在减轻运算成本的同时,因为其较浅的网络无法保证识别的准确度,所以平均精度均低于改进后网络,因此 YOLO_BF 网络拥有最好的性能,更加符合实际应用要求。

表 3 常见目标检测网络性能对比

试验	模型	mAP/%	Params/M	GFLOPs
1	MobileNetV3-v8	65.8	1.1	2.8
2	ShuffleNetV2-v8	63.6	1.8	5.1
3	GhostNet-v8	72.2	2.7	7.5
4	YOLOv5s	75.8	7.0	15.8
5	YOLOv8s	77.6	11.1	28.4
6	Faster-RCNN	71.2	137.08	370.2
7	RT-DETR-L	79.2	31.9	110.0
8	YOLO_BF	78.2	2.74	8.0

为了准确评估本文提出的模型在钢丝绳缺陷检测方面的性能,本文从 RoboflowDBTT 数据集的测试集中精选了部分图像进行评估,如图 10 所示。由于本文算法需运行于在嵌入式设备中,算法的参数规模和计算复杂度 (GFLOPs) 过大会导致设备承受过重的负担,从而无法有效运行,因此本文对比了本文算法 YOLO_BF 与基线网络 YOLOv8n 以及轻量化网络目标检测算法 GhostNet-v8 的预测结果。实际检测效果表明,在处理复杂样本时,YOLO_BF 网络能够准确识别每一个磨损和损伤点,而 YOLOv8n 和 GhostNet-v8 则出现了严重的漏检和误检问题。在矿井作业环境中,经常需要在昏暗条件下进行检测,但这种环境往往使得检测特征变得难以捕捉,导致漏检问题。YOLO_BF 网络得益于 BiFPN 特征融合网络和 BiFormer 注意力机制的协同作用,不仅增强了检测特征的显著性,还有效滤除了背景干扰,确保了在昏暗条件下依然能够维持较低的漏检率,相比之下,YOLOv8n 和 GhostNet-v8 在类似条件下的表现则不尽人意,漏检现象频发。此外,在小目标的识别能力方面,YOLOv8n 和 GhostNet-v8 表现出无法有效识别的问题,而 YOLO_BF 网络则能够实现精确的定位和识别。这些优势使得 YOLO_BF 网络在实际应用中更具潜力和价值。

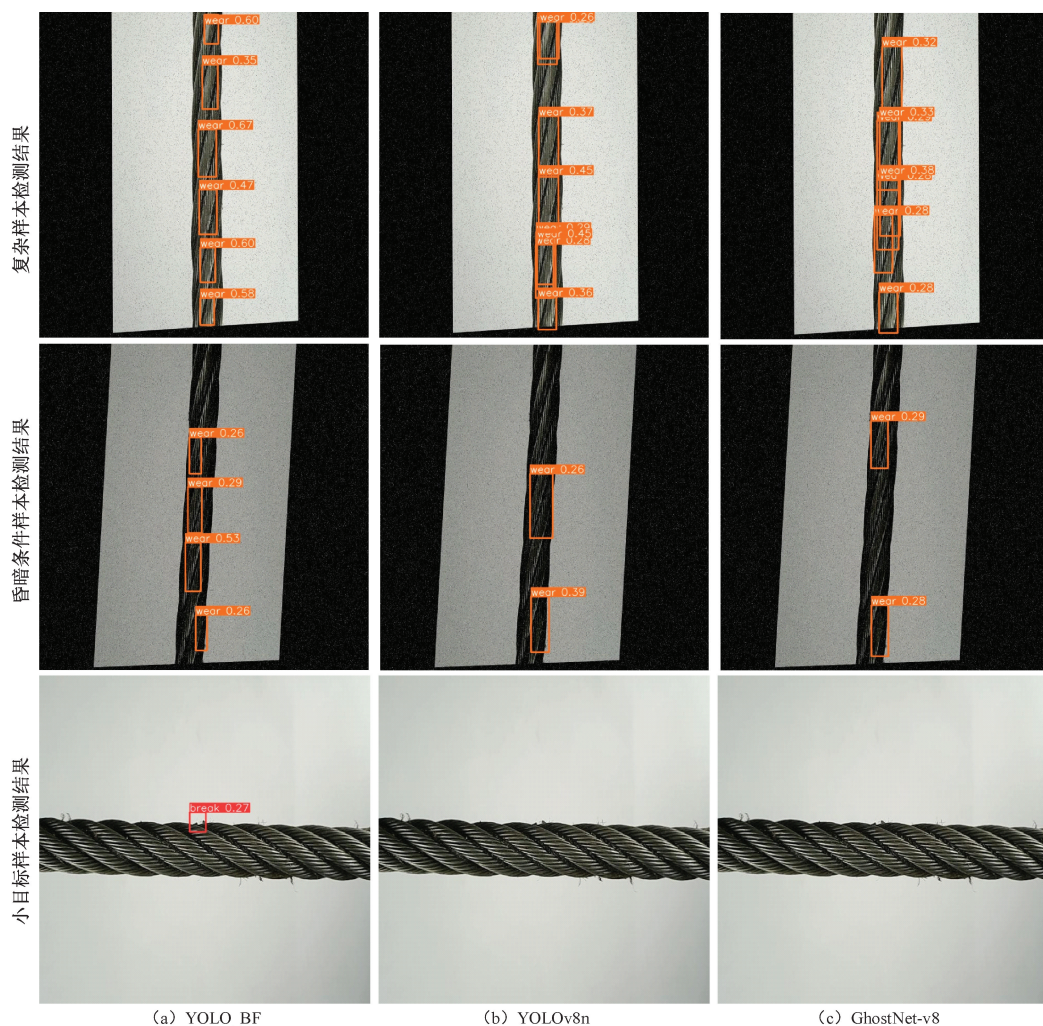


图 10 实际检测结果对比

4 结 论

本文针对煤矿钢丝绳损伤检测领域,提出了一种改进版的 YOLOv8 算法。该算法的核心目标在于,在不提升模型复杂度的前提下,显著增强对钢丝绳表面缺陷的检测精度和效率。确保算法能够在矿井环境中的嵌入式设备上流畅运行,并实现对钢丝绳损伤的精确识别,从而为煤矿安全生产提供强有力的技术支持。本文通过引入改进型双层链路注意力机制 BiFormer、重复加权双向特征金字塔网络 BiFPN、WIoU 损失函数以及幻影卷积 GhostConv 对 Backbone 以及 Neck 网络结构进行改进。在 RoboflowDBTT 数据集上进行测试,与原始 YOLOv8 网络相比,改进后的算法在准确率、召回率和 mAP 方面分别提升了 2.3%、3.3% 和 5.2%。未来的工作将继续提升模型的检测性能并降低复杂度,对模型进行轻量化处理,并进一步探索算法在不同环境下的适应性以及如何将该算法集成到实际的煤矿监测系统中。

参考文献

- [1] 赵文,薛涛,凡成华,等. 矿井提升机钢丝绳损伤在线检测方法研究[J]. 矿山机械, 2022,50(6):22-26.
- [2] HUA L J. Non-destructive testing of coal mine equipment[J]. Machinery Management Development,2017, 32(4):64-65.
- [3] 高升,王巧华,付丹丹,等. 红提糖度和硬度的高光谱成像无损检测[J]. 光学学报, 2019, 39(10): 347-356.
- [4] YAN X L, ZHANG D L, PAN S M, et al. Online nondestructive testing for fine steel wire rope in electromagnetic interference enviroment [J]. NDT&E International,2017,92:75-81.
- [5] 张鑫鹏,黄丽霞,沈佳卉,等. 钢丝绳声发射信号传播特性分析[J]. 失效分析与预防, 2022, 17(1):24-31,36.
- [6] REN L, LIU Z, ZHOU J. Shaking noise elimination for detecting local flaw in steel wire ropes based on

- magnetic flux leakage detection [J]. IEEE Transactions on Instrumentation and Measurement, 2021,70:1-9.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84-90.
- [8] WACKER E S, DENZLER J. Enhanced anomaly detection in wire ropes by combining structure and appearance[J]. Pattern Recognition Letters, 2013, 34(8):942-953.
- [9] SZEGEDY C, LIU W, JIAY Q, et al. Going deeper with convolutions [C]. Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston, MA, USA; IEEE, 2015: 1-9.
- [10] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards realtime object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6):1137-1149.
- [11] CHA Y J, CHOI W, SUH G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9):731-747.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA; IEEE, 2016:770-778.
- [13] 陈荣信, 井陆阳, 白晓瑞, 等. 基于残差网络的钢丝绳损伤图像定量识别[J]. 机床与液压, 2023, 51(12): 24-29.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]. European Conference on Computer Vision. Cham; Springer, 2016:31-37.
- [15] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), IEEE, 2016: 779-788.
- [16] 张乾闯, 郭晨霞, 杨瑞峰, 等. 基于改进 YOLO 算法的光纤环绕制缺陷检测[J]. 电子测量技术, 2023, 46(10):32-39.
- [17] 钱承山, 沈有为, 孙宁, 等. 基于 Transformer 改进 YOLOv5 的山火检测方法研究[J]. 电子测量技术, 2023, 46(16):46-56.
- [18] 高嘉, 刘涛, 王显峰, 等. TWRD-Net: 一种用于曳引钢丝绳缺陷的实时检测网络算法[J]. 仪器仪表学报, 2023, 44(6):223-235.
- [19] 王红尧, 韩爽, 李勤怡. 改进 YOLOv5 的钢丝绳损伤图像识别实验方法研究[J]. 计算机工程与应用, 2023, 59(17):99-106.
- [20] TAN M, PANG R, LE Q V. EfficientDet: Scalable and efficient object detection [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA; IEEE, 2020: 10778-10787.
- [21] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2019:1314-1324.

作者简介

李志星(通信作者), 副教授, 博士, 主要研究方向为人工智能算法、计算机视觉、大数据。

E-mail: onyxlxz@126.com

杨啸龙, 硕士研究生, 主要研究方向为计算机视觉、人工智能。

E-mail: 1090920958@qq.com

李天昊, 硕士研究生, 主要研究方向为计算机视觉、人工智能。

王宁宁, 讲师, 博士, 主要研究方向为图像识别、磁流变液传动。