

张磊,王蒙,孙志鹏,等. 基于GPBW-YOLO的矿用钢丝绳表面损伤检测方法研究[J]. 安全与环境学报, 2026, 26(6): 2162-2174.

ZHANG L, WANG M, SUN Z P, et al. Surface damage detection method for mining wire ropes based on GPBW-YOLO framework [J]. Journal of Safety and Environment, 2026, 26(6): 2162-2174.

基于GPBW-YOLO的矿用钢丝绳表面损伤检测方法研究*

张磊^{1,2,3}, 王蒙¹, 孙志鹏¹, 陶虹京¹, 郑奥¹

(1 山西大同大学煤炭工程学院, 山西大同 037003;

2 煤矿水射流技术与装备厅市共建山西省重点实验室培育基地, 山西大同 037003;

3 山西省矿区地质环境监测与应急减灾技术创新中心, 山西大同 037003)

摘要:随着矿山安全智能化与绿色转型技术的加速推进, 矿井运输系统的安全逐渐成为新质生产力体系中的核心要素。矿用架空乘人装置作为重要的人员运输设备, 其安全运行能够有效保障人员生命安全和生产系统的高效协同。在矿用钢丝绳表面损伤检测任务中, 针对传统人工目视法检测效率低、可靠性差、煤矿未经检查定期更换钢丝绳易造成资源浪费等问题, 提出一种基于轻量化特征增强模型(GhostConv PPA BiFPN WIoUv3 YOLO, GPBW-YOLO)的钢丝绳表面损伤检测方法。首先, 在Backbone部分引入GhostConv, 通过去除冗余特征降低模型复杂度, 提高特征提取效率; 其次, 将并行化补丁感知(Parallelized Patch-Aware Attention, PPA)注意力机制融入C3K2模块中, 其中PPA注意力机制通过损伤区域的先验机制和对损伤特征的位置感知, 有效提高了模型对损伤特征的关注度。再次, 在Neck部分使用双向特征金字塔(Bidirectional Feature Pyramid Network, BiFPN)机制进行多尺度特征融合, 通过结合一种多尺度特征融合权重和跨越阶层式的融合方式, 提高对不同尺度钢丝绳损伤特征的融合效率; 最后, 将WIoUv3作为模型的边界框损失函数, 并引入一种动态梯度增益策略, 该策略降低了高质量样本的竞争性和低质量样本的有害梯度, 可在模型训练的过程中重点关注普通样本带来的梯度效益, 进而提高模型在训练过程中的整体性能。试验结果显示, GPBW-YOLO模型mAP@0.5达到92.0%, 帧率(Frames Per Second, FPS)达到119.0帧/s, 较YOLOv11n分别提高了2.6个百分点和8.4%; 其参数量、计算量和模型存储量分别为1.9 MB、6.2 GB和4.2 MB, 较YOLOv11n分别降低26.9%、1.6%和23.6%, 满足对钢丝绳表面损伤检测的需求。研究为矿山智能运输体系建设提供了相关技术支撑, 有助于推动矿山装备在智能化、安全化与绿色转型方向的发展。

关键词:安全工程; 矿用钢丝绳; 新质生产力; 损伤检测; GPBW-YOLO; 多尺度特征融合

中图分类号: X924.2

文献标志码: A

文章编号: 1009-6094(2026)06-2162-13

DOI: 10.13637/j.issn.1009-6094.2025.1156

0 引言

随着人工智能、物联网以及绿色低碳技术的加速发展, 传统生产方式正在逐步向“新质生产力”转型。“新质生产力”是相对于传统生产力提出的新型生产力形态, 其核心特征在于创新驱动、科技赋能与高质量发展导向, 强调生产要素的数字化、网络化与智能化升级, 并突出绿色低碳与可持续发展在现代产业体系中的重要作用。煤矿能源作为我国能源结构的重要组成部分, 其安全生产是社会重点关注的问题^[1]。在矿井智能化建设的背景下, 人员运输的本质安全逐渐成为矿山系统安稳运行的重要环节。矿用架空乘人装置(也称“猴车”)作为一种高效的矿井人员运输设备, 广泛应用于井下斜坡和巷

道等复杂区域, 显著提高了矿工的运输效率。在矿用架空乘人装置运输过程中, 钢丝绳作为核心承载部件, 直接关系到设备的安全性、稳定性和运行效率, 其是否处于安全状态会直接影响煤矿财产和人员的安全^[2]。近年来, 由于钢丝绳损伤引发的事故时有发生, 2023年6月15日, 山西临县华润联盛黄家沟煤业有限公司发生了一起架空乘人装置钢丝绳反转造成的跑车事故, 事故造成3人遇难、1人重伤、15人轻伤, 直接经济损失约为664.32万元^[3]; 2025年3月, 山西省大同市云冈区晋能控股炭窑峪煤业, 由于钢丝绳断裂, 造成一名支架工死亡。由此可见, 钢丝绳造成的事故不仅导致工作人员伤亡和设备损坏, 还会极大影响煤矿企业经济和社会声誉。

目前, 大多数煤矿企业采用传统人工目视法或

* 收稿日期: 2025-07-09

作者简介: 张磊, 教授, 硕士生导师, 从事智能采矿、图像识别研究, dtblack84@163.com。

基金项目: 山西省重点研发计划项目(202304290000002); 2024年大同市科技计划重点研发高新技术领域项目(2024008)

定期更换钢丝绳的方法来保障钢丝绳的健康状态。人工目视法依赖工作人员经验,容易造成漏检和误检。定期更换钢丝绳指的是煤矿企业按照规定,当钢丝绳使用到一定时间后,不论钢丝绳是否出现损伤都要进行替换,该方法容易造成资源浪费,导致煤矿生产成本增加^[4],违背了绿色转型、智能化矿山建设的目标初衷。因此,设计一种高效率、智能化的钢丝绳表面损伤检测技术,不仅可以提高对钢丝绳表面损伤检测的可靠性,也是实现新质生产力驱动下煤矿装备安全化、智能化、绿色化发展的核心要求。

随着科学技术的不断发展,基于深度学习的目标检测技术逐渐应用于不同的工业场景中^[5-8]。在钢丝绳表面损伤检测领域中,温浩等^[9]使用反向传播神经网络(Back Propagation Neural Network, BPNN)预测客运架空索道中钢丝绳的损伤情况,并建立了单线固定抱索器索道钢丝绳断丝 BPNN 预测模型,最终预测断丝数据和真实数据的最大误差低于 3%。邹磊等^[10]针对钢丝绳缺陷定位问题,提出一种基于 U-Net 图像定位算法模型,在使用编码器提取钢丝绳缺陷特征后,将这些缺陷特征还原为定位标签,实现了更准确地钢丝绳缺陷定位。2020 年,Huang 等^[11]引入卷积神经网络思想,使用卷积神经网络(Convolutional Neural Network, CNN)对钢丝绳表面损伤进行了检测,有效检测出了钢丝绳表面的断丝和磨损类型,比传统的机器学习方法具备更快的检测速度。李金华等^[12]针对矿用架空乘人装置钢丝绳表面损伤问题,提出一种基于 YOLOv3 的钢丝绳检测方法,检测精度达到 91.03%,检测实时性达到 66.8 帧/s。梁滨等^[13]提出一种基于 YOLO 算法框架的曳引钢丝绳缺陷检测方法,提高了钢丝绳缺陷检测的精度。王国锋等^[14]针对多根钢丝绳检测困难、图像质量低等问题,通过图像处理技术对采集的钢丝绳图像进行去噪,并使用改进的 YOLOv5 模型对缺陷进行检测。试验结果显示,与 YOLOv5 相比,该方法提高了断丝检测率、损伤定位准确率等指标。2024 年,方旭东等^[15]首次提出改进通道注意力机制(Convolutional Block Attention Module-Random, CBAM-R),并使用改进的 YOLOv5 (RFC3 CBAM R YOLO, CTR-YOLO)模型对矿井钢丝绳进行检测。该方法增强了矿井钢丝绳小断口、断丝的特征信息,提高了模型对小断口、断丝的特征提取能力,检测精度达到 87.4%。李志星等^[16]针对矿用钢丝绳表面缺陷检测精度低的问题,提出了一种改进 YOLOv8 检测算法(YOLO Bi FPN BiFormer,

YOLO-BF),通过引入注意力机制和优化特征传递方式等方法,对钢丝绳表面缺陷的检测精度达到 78.2%。上述研究通过建立不同的损伤检测模型,实现了对钢丝绳表面损伤类型的分类和预测,但在钢丝绳表面损伤检测任务中仍然存在损伤区域特征难提取、检测精度低、检测实时性差以及漏检等问题。因此,本文提出一种改进 YOLOv11 的矿用钢丝绳表面损伤检测方法,通过引入轻量化幽灵卷积(Ghost Convolution, GhostConv)、并行化补丁感知注意力模块(Parallelized Patch-Aware Attention, PPA)、双向特征金字塔网络(Bidirectional Feature Pyramid Network, Bi FPN)和 WIoUv3 边界框损失函数,进一步提高目标检测模型对钢丝绳表面损伤检测的精度和速度,为构建高效、安全的矿山智能运输系统提供技术手段。

1 GPBW-YOLO 模型

矿井检修场景下的架空乘人装置钢丝绳表面损伤检测任务存在多重挑战:钢丝绳表面断丝、磨损和锈蚀等损伤尺寸和形态差异较大且分布稀疏,同时损伤检测模型需要在边缘计算设备进行部署,对模型的复杂度和实时性有较高要求。因此,本文提出了面向该任务的 GPBW-YOLO 模型,首先使用 GhostConv 减少网络冗余特征与计算量,使模型在资源受限的矿井现场条件下能够稳定部署和高速运行;其次,将 PPA 注意力机制融入 C3K2 结构中,通过位置感知和损伤区域的先验信息使模型在复杂的钢丝绳纹理中能够聚焦断丝、磨损和锈蚀等特征;再次,在特征融合网络引入 Bi FPN 机制,提高对不同尺度的特征融合效率,既保证对细小断丝的检测灵敏性,又兼顾对较大面积磨损的检测效果;最后,使用 WIoUv3 作为边界框回归损失函数,优化模型训练过程。该模型不仅提升了损伤检测的精度与速度,还满足井下资源受限环境的部署需求,其网络结构见图 1。

GPBW-YOLO 模型包含输入端(Input)、主干网络(Backbone)、特征融合网络(Neck)和输出端(Head)4 部分。Backbone 层输入为 640 像素×640 像素的 RGB 图像,经过 Conv 和 GhostConv 的下采样操作,将图像降至 20 像素×20 像素,经过 Mosaic 数据增强后,最终的输入数据结构为[3, 640, 640];Head 中的 3 个检测头分别对应不同尺度特征图(80×80、40×40 和 20×20),所有特征图都包括目标的位置、分类和置信度信息,经过特征提取和融合

后,最终的输出数据结构为 $[N, (C + 4 + 1)]$ 。其中, N 表示预测框数量; C 表示检测的类别数;4表示预测框中心点的横纵坐标 (x, y) 、宽度 w 和高度 h ;1表示检测目标的置信度。

与图1模型结构对应,GPBW-YOLO模型实现算法的形式化描述如下。

(1)输入。模型训练集、验证集和测试集。

(2)初始化参数。训练次数、优化器、学习率、批次输入图像、权重衰减系数。

(3)模型训练网络。**a.** 特征提取阶段:Conv, GhostConv $\times 4$,C3K2-PPA $\times 4$,SPPF,C2PSA。**b.** 特征融合阶段:Conv $\times 2$,上采样 $\times 2$,C3K2 $\times 4$,Bi FPN $\times 3$ 。**c.** 损失计算:边框损失、分类损失、分布损失、总损失值。

(4)模型验证网络。**a.** 模型 w 。**b.** 计算精度指标、速度指标、参数量、复杂度、存储量。**c.** 保存权重 p 。

(5)推理。置信度筛选,非极大值抑制,保存可视化结果。

1.1 GhostConv

工业相机采集的钢丝绳图像表面纹理复杂,直

接使用标准卷积进行特征提取会产生大量冗余特征,同时还会增加计算量与推理延迟,不利于在矿井资源受限设备上的实时部署。为此,GPBW-YOLO在主干网络中使用GhostConv,生成特征图,然后利用计算量很小的廉价线性操作(Cheap Operations)来扩展更多特征信息,这样既保留了钢丝绳断丝、磨损和锈蚀的细节特征,又有效降低了模型复杂度,提高了模型在井下部署的可能性。图2展示了标准卷积模块和Ghost模块的操作过程。Ghost模块将标准卷积过程划分成两个阶段,使用 1×1 卷积操作生成“浓缩”特征图后,将得到的“浓缩”特征图再进行一系列的廉价线性变换得到另一部分Ghost特征图,即相似特征图,最后将上述两部分进行拼接操作并最终输出特征图。

对于标准卷积:假设输入图像 $X \in \mathbf{R}^{w \times h \times c}$ 。其中, $\mathbf{R}$ 代表实数集合, w 和 h 代表输入图像的宽和高, c 代表输入通道数,则生成 N 个特征图的卷积层,计算公式见式(1),标准卷积计算量见式(2)。

$$Y = X * f + b \quad (1)$$

$$M_1 = c \times k \times k \times n \times h' \times w' \quad (2)$$

式中 $f \in \mathbf{R}^{c \times k \times k \times n}$ 为该特征层的卷积核; $Y \in \mathbf{R}^{w' \times h' \times n}$




图1 GPBW-YOLO模型结构

Fig.1 Structure of GPBW-YOLO model




图2 标准卷积模块和 Ghost 模块结构对比

Fig.2 Structural comparison between the standard convolution module and the Ghost module

为含有 n 个输出通道的特征图; $*$ 表示卷积核算子; b 为偏差系数; $k \times k$ 表示卷积核像素; n 表示输出通道数; M_1 表示标准卷积计算量; w' 和 h' 表示输出特征图的宽和高。

Ghost 模块则先使用标准卷积得到“浓缩”特征图[式(3)], 然后对 Y_1 中的每个特征图进行廉价线性操作, 假设每个特征图需要进行 s 次计算[式(4)], 则 Ghost 模块的计算量见式(5)。

$$Y_1 = X * f' \quad (3)$$

$$y_{ij} = \varphi_{i,j}(y'_i) \quad \forall i = 1, 2, \dots, m, j = 1, 2, \dots, s \quad (4)$$

$$M_2 = k \times k \times c \times \frac{n}{s} \times w' \times h' + \frac{n}{s} \times d \times d \times (s - 1) \times w' \times h' \quad (5)$$

式中 Y_1 为经过标准卷积生成的“浓缩”特征图; m 为通道数; $*$ 表示卷积核算子; $f' \in \mathbf{R}^{k \times k \times c \times m}$ 表示当前特征图的卷积核; y_{ij} 表示相似特征图, i 为特征图编号, j 为线性操作的步数; y'_i 表示 Y_1 中第 i 个初始特征图; $\varphi_{i,j}$ 表示作用在第 i 个特征图上的第 j 线性变换; $d \times d$ 表示 Ghost 模块卷积核像素。

通过分析标准卷积模块和 Ghost 模块生成特征图的过程, 可得两者的计算量之比 Q , 见式(6)。由此可得, GhostConv 的计算量是标准卷积的 $1/s$ 。

$$Q = \frac{k \times k \times c \times n}{k \times k \times c \times \frac{n}{s} + \frac{n}{s} \times d \times d \times (s - 1)} \approx \frac{cs}{c + s - 1} \approx s \quad (6)$$

综上所述, Ghost 模块使用计算量较低的线性操作, 在保留标准卷积特征的同时去除了冗余特征信

息, 有效降低了模型复杂度, 提高了特征提取的速度和效率。

1.2 PPA 注意力机制

PPA 注意力机制(Parallelized Patch-Aware Attention, PPA)^[17] 是一种基于先验信息和位置感知的注意力机制, 旨在提升神经网络对特定区域的关注能力。在钢丝绳检测任务中, 损伤部分通常占据整个图像的小部分区域, 且受钢丝绳纹理背景的干扰, 导致模型很难重点关注损伤区域, 容易出现漏检和误检。因此, 本文在 C3K2 模块中引入 PPA 注意力机制, 其通过特征感知(Patch-Aware)来引导模型在特征提取过程中聚焦于损伤区域。PPA 注意力机制结构见图3。输入特征图通过2个并联的“图像块感知”模块进行局部损伤特征提取, 并结合特征选择和注意力机制来进一步增强损伤区域的特征表达, 从而降低钢丝绳复杂纹理背景带来的干扰。




图3 PPA 注意力机制结构

Fig.3 Architecture of the PPA attention mechanism

1.3 Bi FPN 机制

YOLOv11 在 Neck 部分使用路径聚合网络(Path Aggregation Network, PANet)^[18] 结构实现多尺度特征融合, PANet 在特征金字塔网络(Feature Pyramid Networks, FPN)^[19] 的基础上增加了自底向上的特征金字塔, 将浅层的定位特征传输到深层中, 增强了模型在不同尺度上的定位能力。PANet 结构见图4(a)。PANet 包含自顶向下和自底向上两条传输路径, 后者接收的特征信息大多都被前者处理过,

在造成特征冗余的同时还易丢失部分原始特征,从而导致特征融合效率低,因此本文在特征融合网络中引入了 Bi FPN 机制^[20]。




图4 特征金字塔结构

Fig. 4 Architecture of the feature pyramid structure

图4(b)为 Bi FPN 结构。 I_7 和 I_3 层右边的第一个节点仅靠单一输入,不仅对不同层次特征融合贡献较低,还引入了额外计算量。因此, Bi FPN 删除了特征传输能力弱的边缘节点,简化了双向特征金字塔网络结构,减少了网络的冗余,降低了模型复杂度^[21-22]。在钢丝绳损伤识别中,细微断丝和锈蚀需要浅层特征来捕捉细节,而较大范围的磨损则依赖深层特征带来的信息, PANet 在融合这些特征时,对不同特征分配的权重是固定的,不易兼顾多尺度特征的重要性。因此, Bi FPN 在特征融合时,使用了加权特征融合机制,从而使网络能够自适应地判断各输入特征在融合过程中的贡献程度,即让浅层细节信息主要作用于检测微小损伤,让深层全局信息主要作用于检测较大损伤,以实现多尺度损伤的精准检测。 Bi FPN 机制加权特征融合机制如下。

$$O = \sum_{i=0}^N \frac{\omega_i I_i}{\varepsilon + \sum_{j=0}^N \omega_j} \quad (7)$$

式中 O 表示融合后的输出特征图; ω_i 和 ω_j 表示权

重学习参数, i 和 j 表示遍历所有输入的计数标号; ε 表示数值稳定项,取 0.000 1; I_i 表示输入特征。各输入节点带权特征融合计算公式为

$$P_i^{\text{td}} = C_{\text{onv}} \left(\frac{\omega_1 P_i^{\text{in}} + \omega_2 R(P_{i+1}^{\text{in}})}{\omega_1 + \omega_2 + \varepsilon} \right) \quad (8)$$

$$P_i^{\text{out}} = C_{\text{onv}} \left(\frac{\omega'_1 P_i^{\text{in}} + \omega'_2 P_i^{\text{td}} + \omega'_3 R(P_{i-1}^{\text{out}})}{\omega'_1 + \omega'_2 + \omega'_3 + \varepsilon} \right) \quad (9)$$

式中 P_i^{td} 表示第 i 层节点的中间特征; P_i^{in} 表示第 i 层节点的输入特征; P_i^{out} 表示第 i 层节点的输出特征; R 表示对特征图的上采样或下采样操作; C_{onv} 表示卷积运算操作; ω_1 、 ω_2 表示原始权重参数; ω'_1 、 ω'_2 、 ω'_3 表示不同特征在加权融合中的重要程度。

1.4 WIoUv3 损失函数

由于钢丝绳表面不同损伤形态差异较大且边界不规则,导致预测框和目标框匹配难度较大。同时,低质量训练样本也会影响模型精度。 WIoUv3^[23] 作为一种改进的边界框回归损失函数,针对钢丝绳表面损伤检测任务中损伤目标的定位精度和收敛效率的权衡提出了优化思路,该方法在继承 CIoU^[24] 及其变体基础上,引入了一种动态非单调聚焦机制,其核心思想是根据预测框和目标框的匹配质量进行自适应梯度权重的调整,即模型在训练过程中有效并准确地拟合断丝等损伤位置的实际边界。 WIoU 目前包含 v1、v2 和 v3 3 个不同版本, WIoUv1 引入了基于注意力的边界框回归损失,以目标框和预测框的距离为衡量标准进行训练; WIoUv2 在其基础上引入了非单调聚焦系数,降低了低质量样本的权重; WIoUv3 在两者的基础上引入离群度来描述不同锚框质量,并利用离群度来构造非单调聚焦因子,离群度越大,意味着锚框质量越低,非单调聚焦因子值越小。 WIoUv1 的计算公式为

$$L_{\text{WIoUv1}} = R_{\text{WIoU}} L_{\text{IoU}} \quad (10)$$

$$R_{\text{WIoU}} = \exp \left(\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(W_g^2 + H_g^2)^*} \right) \quad (11)$$

$$L_{\text{IoU}} = 1 - \text{IoU} \quad (12)$$

式中 L_{WIoUv1} 为 WIoUv1 函数; R_{WIoU} 为权重系数惩罚项; L_{IoU} 为预测框和目标框重叠面积的交并比; x_{gt} 和 y_{gt} 表示目标框的中心点坐标; x 和 y 表示预测框中心点坐标; W_g 和 H_g 表示目标框和预测框最小外接矩形的宽和高; $*$ 表示将 W_g 和 H_g 从计算图中进行分离。 WIoUv3 的计算公式为

$$L_{\text{WIoUv3}} = \frac{\beta}{\delta \alpha^{\beta-\delta}} \exp \left(\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(W_g^2 + H_g^2)^*} \right) L_{\text{IoU}} \quad (13)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}^m} \quad (14)$$

$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (15)$$

式中 β 为离群度,用来衡量锚框的质量; α 和 δ 均为模型学习参数; L_{IoU}^* 为修正后的 IoU 损失; L_{IoU}^m 为动态变量; r 为非单调聚焦系数。

2 试验与分析

2.1 试验装置与数据集

为制作钢丝绳表面损伤数据集,在试验室搭建钢丝绳表面损伤图像采集试验台,见图 5。试验台主要由电机驱动系统和图像采集系统等组成,该试验台基于矿用架空乘人装置钢丝绳运行原理制成。电机驱动系统包括电机控制器、调速驱动电机、钢丝绳驱动轮、钢丝绳从动轮;图像采集系统包括 CMOS 工业相机(MV-CA005-20GC,海康威视)、工业光源(KM-2BRD12020,科麦视觉)、光源控制器、光源反射板以及上位机。为了对钢丝绳全方位监测,3 个工业相机相互角度为 120° ;为了获得较为均匀的光线,3 个工业光源采用高角度照射方法,将光源布置于摄像头高度;为减少金属表面的反光,工业光源与相机呈 60° 布置。使用该试验台获取钢丝绳表面损伤图像,CMOS 工业相机发光尺寸为 $120 \text{ mm} \times 20 \text{ mm}$;接口数量为 4;CMOS 工业相机与上位机通过 USB 接口完成通信。




图 5 钢丝绳表面损伤图像采集试验台

Fig.5 Experimental platform for image acquisition of surface damage on steel wire ropes

数据集样本主要通过试验室搭建采集装置进行采集,随后通过图像翻转、旋转、缩放以及自适应直方图均衡化^[25]等操作,制作包含 3 000 张不同形态、角度的钢丝绳表面损伤图像。其中,“break”表示断丝、“wear”表示磨损、“corrosion”表示锈蚀。同时,按照数量比为 8:1:1 的比例随机划分为训练集

(2 400 张)、验证集(300 张)和测试集(300 张),不同类型损伤标签分布见表 1。

表 1 损伤类型标签分布

Table 1 Distribution of damage type labels

钢丝绳损伤类型分布	断丝标签	磨损标签	锈蚀标签
训练集	1 653	1 002	1 055
验证集	179	119	160
测试集	222	122	122
总计	2 054	1 243	1 337

2.2 试验环境与参数

试验软硬件参数见表 2。

表 2 试验软硬件配置

Table 2 Experimental hardware and software configuration

软/硬件	型号/版本号
操作系统	Windows 11
深度学习框架	Pytorch 1.13.1
Python 版本	3.10
CPU	Intel i9-13900K CPU @ 3.00 GHz
GPU	NVIDIA GeForce RTX 4090

本文使用 GPU 进行模型的训练和推理,输入图像尺寸为 $640 \text{ 像素} \times 640 \text{ 像素}$;批次输入图像数量为 32 张;模型训练次数为 300 轮;训练优化器为 SGD;初始学习率为 0.01;权重衰减系数为 0.000 5。

2.3 模型评价指标

为验证 GPBW-YOLO 模型性能,本文采用平均精度均值(Mean Average Precision, mAP)和帧率(Frames Per Second, FPS)作为模型检测性能的主要评价指标,其计算公式如下。

$$M_{\text{mAP}} = \frac{\sum_{i=1}^N A_{p_i}}{N} \quad (16)$$

$$A_p = \int_0^1 P(R) dR \quad (17)$$

$$P = \frac{T_p}{T_p + F_p} \quad (18)$$

$$R = \frac{T_p}{T_p + F_N} \quad (19)$$

式中 M_{mAP} 表示评价精度均值, T_p 表示待检测目标被正确预测的正样本数; F_p 表示待检测目标被错误预测的负样本数; F_N 表示待检测目标被错误预测的正样本数; N 表示待检测物体的类别; A_p 表示平均

精度; P 为查准率; R 为召回率,此外,为了更好地体现模型在轻量化方面的性能,使用参数量、计算量以及存储量对模型进行评估。

2.4 轻量化卷积对比试验

在轻量化卷积选取过程中,精度与复杂度之间的权衡分析至关重要,不同轻量化卷积的相同之处是能够有效降低模型复杂度,但在检测精度和速度上存在一定差异。在矿井钢丝绳损伤检测场景下,需要模型准确、快速地识别,如果追求极致的轻量化可能导致模型出现漏检和误检,而追求极致的精度可能导致模型复杂度较高,不易在设备上部署。因此,需要从检测精度、实时性和复杂度等多方面进行考虑,选取综合性能最优的模块进行集成。本文选用深度可分离卷积 (Depth-Wise Convolution, DWConv)、分组混洗卷积 (Generalized Shuffle Convolution, GSConv) 和 GhostConv 进行试验对比,且均在相同的试验环境和数据集下进行,不同轻量化卷积模块对比结果见表 3。

从表 3 可知,在检测精度方面,当引入 GhostConv 后,模型对钢丝绳表面损伤检测的 mAP@0.5 达到 90.7%,比 YOLOv11n 提高了 1.3 百分点,同时优于 GSConv 和 DWConv,表明 GhostConv 更好地保留了损伤特征的关键信息,有效提升了检测精度。同时, DWConv 的 mAP@0.5 比 YOLOv11n 降低了 0.2 百

分点,表明 DWConv 会丢失部分损伤特征,尤其是对细微断丝和锈蚀特征,比 GhostConv 和 GSConv 差。在实时性方面, GhostConv 的 FPS 为 136.9 帧/s,优于 YOLOv11n 和 GSConv,但略低于 DWConv,虽然 DWConv 的 FPS 略高于 GhostConv,但其在精度方面存在不足,比 GhostConv 下降了 1.5%。在资源占用方面, GhostConv 的存储量略高于 DWConv,持平于 GSConv,低于 YOLOv11n,表现较优; GhostConv 会使用标准卷积生成一部分特征,因此参数量和计算量会略高于 DWConv,其参数量和计算量分别 2.3 MB 和 5.6 GB,仍处在较低水平。总而言之, GhostConv 在保持模型较低复杂度的同时,能够更全面地捕获损伤特征,同时在模型精度、实时性和复杂度方面保持了较优平衡,更适用于矿井资源受限场景,满足实时检测的需求。

2.5 注意力机制对比试验

在钢丝绳表面损伤检测任务中,钢丝绳表面存在不同类型损伤,比如断丝、磨损和锈蚀等,其分布区域和损伤形态都不相同,且容易受钢丝绳本身背景的影响,这些因素对目标检测模型具有一定挑战。本文选取现有的高效多尺度注意力机制 (Efficient Multi-Scale Attention, EMA)、卷积块注意力机制 (Convolutional Block Attention Module, CBAM) 和“挤压-激励”注意力机制 (Squeeze-and-Excitation

表 3 不同轻量化卷积对比结果

Table 3 Comparison results of different lightweight convolutions

卷积	查准率/%	召回率/%	mAP@0.5/%	FPS/(帧·s ⁻¹)	存储量/ MB	参数量/ MB	计算量/ GB
YOLOv11n	84.7	84.1	89.4	109.8	5.5	2.6	6.3
+ GhostConv	85.1	85.2	90.7	136.9	5.0	2.3	5.6
+ GSConv	83.9	83.7	89.5	128.2	5.0	2.3	5.6
+ DWConv	84.2	83.7	89.2	140.8	4.5	2.1	4.9

表 4 不同注意力机制对比试验

Table 4 Comparison experiment of different attention mechanisms

注意力机制	查准率/%	召回率/%	mAP@0.5/%	存储量/MB	参数量/MB	计算量/GB
YOLOv11n	84.7	84.1	89.4	5.5	2.6	6.3
+ EMA	84.3	86.9	90.4	5.5	2.6	6.4
+ PPA	87.8	83.4	90.8	6.0	4.8	7.9
+ CBAM	84.5	82.1	90.1	5.6	2.6	6.4
+ SENet	88.6	82.4	89.9	5.5	2.6	6.3
+ C3K2-PPA	86.3	84.9	91.1	6.0	2.8	7.0

Networks, SENet) 与 PPA 注意力机制进行对比,且均在相同的试验环境和数据集下进行,试验结果见表 4。

从表 4 可知,在 YOLOv11n 中引入不同注意力机制后,模型整体的精度均有所提升。EMA、CBAM 和 SENet 分别将 mAP@0.5 提升至 90.4%、90.1%、89.9%,PPA 注意力机制表现最优,mAP@0.5 达到 90.8%,表明 PPA 注意力机制能够有效提高模型对钢丝绳损伤区域的关注程度,保持较高的检测精度。在模型复杂度方面,EMA、CBAM 和 SENet 基本没有增加计算开销,而 PPA 注意力机制虽然提供了较高的精度,但导致较大的计算开销。因此,本文将 PPA 注意力机制与 C3K2 模块集成,C3K2 是重要的特征提取组件,通过结合可变卷积核($3 \times 3, 5 \times 5$),提供了较强的特征提取能力,而 PPA 注意机制则强化了对关键损伤区域特征的关注,两者形成互补。PPA 在结合 C3K2 模块后,模型检测性能显著增加,mAP@0.5 由 90.8% 提升至 91.1%,较 YOLOv11n 提高了 1.7 百分点,在各注意力机制中表现最好。此外,C3K2-PPA 的参数量和计算量比 PPA 注意力机制分别下降 0.2 MB 和 0.9 GB,进一步减小了模型计算开销。虽然 C3K2-PPA 的复杂度略高于其他注意力机制,但其精度显著提升,符合矿井钢丝绳检测场景对模型高精度和轻量化的需求。

2.6 损失函数对比试验

损失函数是一个综合指标,在模型训练过程中用于优化目标检测精度。YOLOv11 模型主要包含边界框损失(box_loss)、分类损失(cls_loss)和分布损失(dfl_loss),其中 box_loss 可衡量预测边界框与真实边界框之间的差异;cls_loss 可评估预测目标类别的准确性;dfl_loss 可解决检测类别不平衡问题。损失函数值越低,表明预测值越接近真实值,模型训练效果越好。本文选用 CIoU、SIoU、EIoU 和 WIoUv3 损失函数进行对比试验,且均在相同的试验环境和数据集下进行,试验结果见表 5。

从表 5 可知,在引入不同损失函数后,模型参

数量、浮点计算量和模型存储量 3 列数据没有发生变化,表明引入不同的损失函数并不会引入过多的复杂度。其中,SIoU 的 mAP@0.5 为 87.9%,较 YOLOv11n 下降了 1.5 百分点,这是因为其更偏向于预测框和目标框角度及方向的优化,对于较小的损伤目标,可能会出现定位不准确的情况,进而降低了检测精度;EIoU 的 mAP@0.5 为 89.2%,略低于 YOLOv11n,其在 YOLOv11n 的基础上加入了长宽比,强调边界框长宽比的一致性,但钢丝绳损伤形态复杂,降低了对部分损伤目标的泛化能力;WIoUv3 的 mAP@0.5 为 90.5%,较 YOLOv11n、SIoU 和 EIoU 分别提高 1.1 百分点、2.6 百分点和 1.3 百分点,表现最优。凭借 WIoUv3 的特殊加权机制,使模型在训练过程中自适应重叠度,有效提升了对钢丝绳损伤目标的检测精度。

2.7 消融试验

消融试验是一种通过逐步添加或修改模型中的某些模块,并评估这些模块对模型性能贡献值的一种试验方法。为了验证不同改进模块对基线模型的优化效果,本文共设计了 8 组试验,且均在相同的试验环境和数据集下进行,消融试验结果见表 6。模型 A、B、C、D 分别代表 GhostConv、C3K2-PPA、Bi FPN 和 WIoUv3 模块。基线模型的 mAP@0.5 为 89.4%,FPS 为 109.8 帧/s,查准率为 84.7%,召回率为 84.1%,参数量为 2.6 MB,计算量为 6.3 GB,存储量为 5.5 MB,这些指标为不同模块的集成提供了基准,能够有效量化不同模块对模型性能的影响。

由表 6 试验 2 可以看出,使用 GhostConv 使 mAP@0.5 比基线模型提高了 1.3 百分点,且模型参数量、浮点计算量和存储量分别下降了 0.3 MB、0.7 GB 和 0.5 MB,FPS 提高了 24.6%,表明 GhostConv 通过“浓缩”特征生成和廉价的线性操作,既降低了模型复杂度,又很好地保留了损伤特征信息;由试验 3 可以看出,引入 C3K2-PPA 使 mAP@0.5 指标比基线模型提高了 1.7 百分点,但其模型复杂度,模型参数量、浮点计算量和存储量分别上升 0.2 MB、0.7 GB

表 5 不同损失函数对比试验

Table 5 Comparison experiment of different loss functions

损失函数	查准率/%	召回率/%	mAP@0.5/%	存储量/MB	参数量/MB	计算量/GB
YOLOv11n	84.7	84.1	89.4	5.5	2.6	6.3
WIoUv3	88.2	84.1	90.5	5.5	2.6	6.3
SIoU	83.9	82.8	87.9	5.5	2.6	6.3
EIoU	85.6	85.3	89.2	5.5	2.6	6.3

表6 消融试验结果
Table 6 Results of ablation experiments

序号	A	B	C	D	查准率/ %	召回率/ %	mAP@ 0.5/%	FPS / (帧·s ⁻¹)	参数量/ MB	计算量/ GB	存储量/ MB
1	—	—	—	—	84.7	84.1	89.4	109.8	2.6	6.3	5.5
2	✓	—	—	—	85.1	85.2	90.7	136.9	2.3	5.6	5.0
3	—	✓	—	—	86.3	84.9	91.1	104.9	2.8	7.0	6.0
4	—	—	✓	—	88.4	82.3	91.4	120.4	1.9	6.0	4.1
5	—	—	—	✓	88.2	84.1	90.5	109.9	2.6	6.3	5.5
6	✓	✓	—	—	87.5	84.4	91.3	100.2	2.5	6.4	5.5
7	✓	✓	✓	—	87.4	84.3	91.7	117.6	1.8	5.8	4.0
8	✓	✓	✓	✓	88.2	85.7	92.0	119.0	1.9	6.2	4.2

注:“—”表示未引入集成模块,“✓”表示引入集成模块。

和0.5 MB, FPS降低4.5%,表明在C3K2中引入PPA注意力机制能够有效提高模型对钢丝绳表面损伤特征的检测精度,但也会略微地提高模型复杂度;由试验4可以看出,引入BI FPN使mAP@0.5指标比基线模型提高了2.0个百分点,且模型参数量、浮点计算量和存储量分别下降0.7 MB、0.3 GB和1.4 MB, FPS提高9.6%,表明引入Bi FPN提高了不同特征尺度的融合效率,进一步增强了模型的性能;由试验5可以看出,将损失函数替换为WIoUv3时, mAP@0.5比基线模型提高了1.1个百分点,模型复杂度没有变化,表明WIoUv3使模型在训练过程中,减少了低质量锚框带来的有害影响,提高了模型检测精度。

由试验6可以看出,在同时引入GhostConv和C3K2-PPA时,模型的mAP@0.5指标在试验2的基础上有所提高,且复杂度在试验3的基础上有所下降,模型参数量、浮点计算量和存储量分别下降0.3 MB、0.6 GB和0.5 MB,模型以良好的趋势继续发展;受试验5的启发,试验7在试验6的基础上引入Bi FPN,模型的mAP@0.5指标提高了0.4个百分点, FPS提高了17.3%,模型复杂度进一步下降;试验8是本文是最终改进模型,集成4个模块后的模型的mAP@0.5比基线模型提高了2.6个百分点,模型参数量、浮点计算量和模型存储量分别降低了26.9%、1.6%和23.6%, P 和 R 分别提高了3.5个百分点和1.6个百分点, FPS提高了8.4%,综合性能最优。

2.8 主流模型对比试验

为验证GPBW-YOLO模型的优越性,本文与其他主流的目标检测模型进行对比,包括YOLOv3-Tiny^[26]、YOLOv5s^[27]、YOLOv7-Tiny^[28]、YOLOv8n^[29]和

YOLOv11n等模型。所有对比试验均在相同试验环境和数据集下进行,试验结果见表7,不同模型检测精度对比曲线和模型轻量化参数对比见图6。

由表7可知, YOLOv3-Tiny和YOLOv5的mAP@0.5和FPS指标有良好的表现,但模型复杂度较





图6 不同模型各性能指标对比

Fig. 6 Comparison of performance metrics across different models

表 7 不同模型对比试验结果

Table 7 Comparative experimental results of different models

模型	mAP@0.5/%	参数量/MB	计算量/GB	存储量/MB	FPS/(帧·s ⁻¹)
YOLOv3-Tiny	89.9	9.5	14.3	19.2	122.6
YOLOv5s	90.5	7.0	14.4	15.8	126.6
YOLOv8n	88.9	3.0	8.1	6.3	95.2
YOLOv11n	89.4	2.6	6.3	5.5	109.8
GPBW-YOLO	92.0	1.9	6.2	4.2	119.0



A 是钢丝绳表面断丝图像,A1~A4 是不同模型对表面断丝的检测结果;B 是钢丝绳表面磨损图像,B1~B4 是不同模型对表面磨损的检测结果;C 是钢丝绳表面锈蚀图像,C1~C4 是不同模型对表面锈蚀的检测结果。

图 7 不同模型检测效果对比

Fig. 7 Comparison of detection performance across different models

高。YOLOv8n 和 YOLOv11n 模型在模型参数量、浮点计算量和存储量方面有所优化,但 mAP@0.5 指标低于 GPBW-YOLO 模型。GPBW-YOLO 模型的 mAP@0.5 指标为 92.0%,较 YOLOv3-Tiny、YOLOv5s、YOLOv8n 和 YOLOv11n 分别提高了 2.1 百分点、1.5 百分点、3.1 百分点和 2.6 百分点。此外,GPBW-YOLO 的 FPS 达到 119.0 帧/s,较 YOLOv11n 提高了 8.4%,仅次于 YOLOv3-Tiny 和 YOLOv5s 模型。同时,GPBW-YOLO 模型参数量、浮点计算量和模型存储量分别为 1.9 MB、6.2 GB 和 4.2 MB,均低于其他目标检测模型。综上所述,GPBW-YOLO 模型性能的综合表现最优,满足钢丝绳表面损伤检测任务。

为验证 GPBW-YOLO 模型的检测性能,本文使用 YOLOv5s、YOLOv8n、YOLOv11n 和 GPBW-YOLO 模型对钢丝绳表面的 3 类损伤在测试集上进行检

测,检测效果见图 7。

由图 7 可知,在 A1~A4 中,YOLOv8n 模型对钢丝绳表面断丝出现了漏检,YOLOv5s、YOLOv11n 和 GPBW-YOLO 模型均准确无误地识别了断丝,且 GPBW-YOLO 置信度最高,最高达到 95.0%;在 B1~B4 中,4 类模型均识别出钢丝绳表面磨损,GPBW-YOLO 置信度最高,YOLOv11n 次之;在 C1~C4 中,YOLOv5s 和 YOLOv8n 对微小锈蚀出现了漏检现象,YOLOv11n 和 GPBW-YOLO 均正确识别了所有目标,且 GPBW-YOLO 的置信度更高。综上所述,GPBW-YOLO 模型比 YOLOv5s、YOLOv8n 和 YOLOv11n 的检测效果更优,可有效改善漏检情况,整体检测精度较高。

3 结 论

(1) 本文提出一种 GPBW-YOLO 模型,试验结

果显示该模型的 mAP@0.5 为 92.0%, FPS 达到 119.0 帧/s, 参数量为 1.9 MB, 计算量为 6.2 GB, 模型存储量为 4.2 MB。该模型在提高检测精度的同时还拥有轻量化特性, 满足矿山井下环境对模型边缘部署、高效响应的实际需求, 契合新质生产力对矿山装备智能化、安全化和绿色化转型的发展导向。

(2) 基于 YOLOv11n 模型提出了 4 种改进方法, 在主干部分引入 GhostConv, 既降低了模型复杂度又提高了对钢丝绳表面损伤特征的提取能力; 在 C3K2 模块中引入 PPA 注意力机制, 有效提高了模型的检测精度; 在 Neck 部分引入 Bi FPN 机制, 提高了钢丝绳表面损伤多尺度特征的融合效率; 引入 WIoUv3 作为边界框损失函数, 降低了低质量样本带来的有害梯度, 提高了模型性能。GPBW-YOLO 模型在检测精度和模型轻量化方面均优于 YOLOv11n。

(3) GPBW-YOLO 模型能较好地检测钢丝绳表面损伤, 提高钢丝绳表面损伤的风险预警能力, 并改善其他目标检测模型出现的漏检现象, 不仅为矿用架空乘人装置钢丝绳安全监测提供了一种技术手段, 也为矿山智能化运输体系建设加入了新质生产力支撑, 可助力煤矿安全管理的绿色转型和智能化发展。

参考文献 (References):

- [1] 邓军, 王津睿, 任帅京, 等. 采空区煤自燃高温点识别与探测技术研究与发展[J]. 煤炭学报, 2024, 49(2): 885-901.
DENG J, WANG J R, REN S J, et al. Identification and detection technology for high-temperature spontaneous combustion points in goaf areas[J]. Journal of China Coal Society, 2024, 49(2): 885-901.
- [2] 井陆阳. 钢丝绳断丝损伤定量识别关键技术研究[D]. 青岛: 青岛理工大学, 2012.
JING L Y. Research on key technologies for quantitative identification of broken wire damage in steel wire rope [D]. Qingdao: Qingdao University of Technology, 2012.
- [3] 王佳丽. 39 名相关责任人被追问责[N]. 山西经济日报, 2024-01-10(2).
WANG J L. 39 responsible persons held accountable [N]. Shanxi Economic Daily, 2024-01-10(2).
- [4] 殷勇辉, 冯永贵, 张海涛. 基于磁通平衡原理的钢丝绳动态探伤系统[J]. 矿山机械, 2015, 43(5): 57-61.
YIN Y H, FENG Y G, ZHANG H T. Dynamic detection system for wire rope based on flux balance principle[J]. Mining Machinery, 2015, 43(5): 57-61.
- [5] 周茂军, 胡江涛, 王俊杰, 等. 改进 SSD 算法在工件表面缺陷检测中的应用[J]. 组合机床与自动化加工技术, 2024(8): 139-144.
ZHOU M J, HU J T, WANG J J, et al. Application of improved SSD algorithm in surface defect detection of workpieces[J]. Combined Machine Tool & Automated Machining Technology, 2024(8): 139-144.
- [6] 林自强, 李明, 刘张榕. 基于改进的 SECOND 网络与 MobileNetV2 网络的视频监控与追踪技术实现[J]. 测控技术, 2024, 43(5): 78-84.
LIN Z Q, LI M, LIU Z R. Implementation of video monitoring and tracking technology based on improved SECOND network and MobileNetV2 network [J]. Measurement and Control Technology, 2024, 43(5): 78-84.
- [7] 邓力, 周进, 刘全义. 改进型 YOLOv8 算法在火灾探测中的应用[J]. 安全与环境学报, 2025, 25(3): 888-897.
DENG L, ZHOU J, LIU Q Y. Fire detection algorithm based on an improved YOLOv8 model [J]. Journal of Safety and Environment, 2025, 25(3): 888-897.
- [8] 陈婷, 斯小瑞, 何自芬, 等. 面向施工现场安全帽检测改进的 YOLOv8n-DM 算法研究[J]. 安全与环境学报, 2024, 24(12): 4769-4778.
CHEN T, SI X R, HE Z F, et al. Research on the enhanced YOLOv8n-DM algorithm for safety helmet detection at construction sites[J]. Journal of Safety and Environment, 2024, 24(12): 4769-4778.
- [9] 温浩, 刘兆羽, 陈琳. 基于 BP 神经网络的索道钢丝绳损伤研究[J]. 起重运输机械, 2023(7): 34-38.
WEN H, LIU Z Y, CHEN L. Research on rope damage of ropeway based on BP neural network[J]. Crane and Transport Machinery, 2023(7): 34-38.
- [10] 邹磊, 冯治国, 梁鹏翔, 等. 基于 U-Net 的启闭机钢丝绳缺陷定位方法研究[J]. 国外电子测量技术, 2024, 43(9): 155-160.
ZOU L, FENG Z G, LIANG P X, et al. The research on steel wire rope breakage fault localization based on U-Net [J]. Foreign Electronic Measurement Technology, 2024, 43(9): 155-160.
- [11] HUANG X, LIU Z, ZHANG X, et al. Surface damage detection for steel wire ropes using deep learning and computer vision techniques [J]. Measurement, 2020, 161: 107843.

- [12] 李金华, 夏黎明. 图像识别技术在矿用钢丝绳检测中的应用[J]. 山西焦煤科技, 2022, 46(4): 16-18.
- LI J H, XIA L M. Application of image recognition technology in mining wire rope detection[J]. Shanxi Coking Coal Science and Technology, 2022, 46(4): 16-18.
- [13] 梁滨, 宋雪峰, 高嘉, 等. 基于 YOLO 算法框架的曳引钢丝绳缺陷检测方法[J]. 无损探伤, 2023, 47(6): 1-4.
- LIANG B, SONG X F, GAO J, et al. Defect detection method of steel wire rope based on YOLO algorithm[J]. Non-destructive Testing, 2023, 47(6): 1-4.
- [14] 王国锋, 王守军, 陶荣颖, 等. 矿井提升机钢丝绳外观缺陷视觉识别技术研究[J]. 工矿自动化, 2024, 50(5): 28-35.
- WANG G F, WANG S J, TAO R Y, et al. Research on visual recognition technology for appearance defects of steel wire rope in mine hoist[J]. Journal of Mine Automation, 2024, 50(5): 28-35.
- [15] 方旭东, 于正, 杨发展, 等. 基于注意力机制的轻量级矿井钢丝绳断丝检测算法研究[J]. 中国煤炭, 2024, 50(8): 152-164.
- FANG X D, YU Z, YANG F Z, et al. Research on broken wire detection algorithm of lightweight mine steel wire rope based on attention mechanism[J]. China Coal, 2024, 50(8): 152-164.
- [16] 李志星, 杨啸龙, 李天昊, 等. 基于 YOLOv8 的煤矿用钢丝绳损伤检测算法[J]. 电子测量技术, 2024, 47(9): 120-128.
- LI Z X, YANG X L, LI T H, et al. YOLOv8-based surface damage detection of mine wire rope[J]. Electronic Measurement Technology, 2024, 47(9): 120-128.
- [17] XU S B, ZHENG S C, XU W H, et al. HCF-Net: hierarchical context fusion network for infrared small object detection[C]//Proceedings of the 2024 IEEE International Conference on Multimedia and Expo, June 15-19, 2024, Niagara Falls, Canada. New York: IEEE, 2024: 1-6.
- [18] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, USA. New York: IEEE, 2018: 8759-8768.
- [19] GAO Z, LI Z, ZHANG C, et al. Double self-attention based fully connected feature pyramid network for field crop pest detection[J]. Computers, Materials & Continua, 2025, 83(3): 4353-4371.
- [20] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 14-19, 2020, Seattle, USA. New York: IEEE, 2020: 10781-10790.
- [21] 黄崇庆, 徐慧英, 张晓雷, 等. BGR-YOLO: 基于 YOLOv8 改进的交通场景下目标检测算法[J/OL]. 计算机工程与科学: 1-13[2025-09-01]. <https://link.cnki.net/urlid/43.1258.TP.20250408.1455.002>.
- HUANG C Q, XU H Y, ZHANG X L, et al. BGR-YOLO: an improved object detection algorithm under traffic scenarios based on YOLOv8[J/OL]. Computer Engineering & Science: 1-13[2025-09-01]. <https://link.cnki.net/urlid/43.1258.TP.20250408.1455.002>.
- [22] ZHAO J, ZHU H, NIU L. BiTNet: a lightweight object detection network for real-time classroom behavior recognition with transformer and bi-directional pyramid network[J]. Journal of King Saud University-Computer and Information Sciences, 2023, 35(8): 1319-1578.
- [23] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[PP/OL]. [2025-07-01]. <https://arxiv.org/abs/2301.10051v3>.
- [24] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [25] LI C, ZHU J, BI L, et al. A low-light image enhancement method with brightness balance and detail preservation[J]. PLoS One, 2022, 17(5): 1-40.
- [26] REDMON J, FARHADI A. YOLOv3: an incremental improvement[PP/OL]. [2025-07-01]. <https://arxiv.org/abs/1804.02767v1>.
- [27] SONG Q S, LI S B, BAI Q, et al. Object detection method for grasping robot based on improved YOLOv5[J]. Micromachines, 2021, 12(11): 1273-1273.
- [28] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 17-24, 2023, Vancouver, Canada. New York: IEEE, 2023: 7464-7475.
- [29] HU K, LIN H C, JIN X, et al. Meta-YOLOv8: multi-

scale few-shot object detection for Chinese medicinal
decoction pieces [J]. Journal of King Saud University

Computer and Information Sciences, 2025, 37 (7):
201.

Surface damage detection method for mining wire ropes based on GPBW – YOLO framework

ZHANG Lei^{1,2,3}, WANG Meng¹, SUN Zhipeng¹, TAO Hongjing¹, ZHENG Ao¹

(1 College of Coal Engineering, Shanxi Datong University, Datong 037003, Shanxi, China;

2 Shanxi Key Laboratory Cultivation Base for Municipal and Provincial Co-Construction of Coal Mine

Water Jet Technology and Equipment, Datong 037003, Shanxi, China;

3 Shanxi Provincial Mining Area Geological Environment Monitoring and Emergency Disaster Reduction

Technology Innovation Center, Datong 037003, Shanxi, China)

Abstract: With the rapid advancement of intelligent and green transformation technologies in mining safety, the security of mine transportation systems has increasingly become a core component of the new productivity framework. As a crucial personnel transportation device, the safe operation of mine overhead passenger carriers is essential for ensuring both personnel safety and the efficient coordination of production systems. In addressing the challenge of surface damage detection in mine steel wire ropes, this study proposes a novel detection method based on a lightweight feature enhancement model (GhostConv PPA BiFPN WIoUv3 YOLO, GPBW – YOLO). This approach aims to overcome the limitations of traditional manual visual inspection methods, which are often characterized by low detection efficiency and poor reliability, as well as the resource waste associated with the regular replacement of steel wire ropes without proper inspection in coal mines. Firstly, GhostConv is implemented in the Backbone component to reduce model complexity and enhance feature extraction efficiency by eliminating redundant features. Secondly, the Parallelized Patch-Aware Attention (PPA) mechanism is integrated into the C3K2 module, effectively improving the model's focus on damage characteristics through prior knowledge of damage areas and enhanced perception of damage feature locations. Next, the Bidirectional Feature Pyramid Network (Bi FPN) mechanism is utilized in the Neck section for multi-scale feature fusion. By combining a multi-scale feature fusion weight with a cross-layer fusion method, the efficiency of fusing damage features at various scales of steel wire ropes is significantly improved. Finally, WIoUv3 is introduced as the bounding box loss function of the model, accompanied by the implementation of a dynamic gradient gain strategy. This strategy diminishes the influence of high-quality samples while mitigating the detrimental gradients from low-quality samples, thereby emphasizing the gradient advantages provided by ordinary samples during the model training process. This approach ultimately enhances the overall performance of the model throughout training. Experimental results demonstrate that the GPBW – YOLO model achieves a mAP@0.5 of 92.0% and a FPS of 119.0 frame/s, representing improvements of 2.6 percentage point and 8.4%, respectively, compared to YOLOv11n. The GPBW – YOLO model has a parameter count of 1.9 MB, a computational cost of 6.2 GB, and a model weight size of 4.2 MB, which are reductions of 26.9%, 1.6%, and 23.6%, respectively, compared to YOLOv11n. These efficiencies align with the requirements for surface damage detection in steel wire ropes. The research presented in this paper offers valuable technical support for the development of intelligent mine transportation systems and contributes to advancing mining equipment towards greater intelligence, safety, and environmentally friendly transformation.

Key words: safety engineering; mining wire ropes; new quality productivity; damage detection; GPBW – YOLO; multiscale feature fusion