

基于改进 YOLOv9 算法的钢丝绳表面缺陷检测

李乐军, 梁国伟

(国家电投集团山西电力有限公司, 太原 030001)

摘要: 针对钢丝绳表面尺寸较小的断丝和磨损缺陷的检测精度与实时性的需求, 基于 YOLOv9 框架进行了算法优化; 通过引入 PGI 辅助监督机制增强梯度信息传播, 构建 GELAN 高效特征提取架构, 并设计多尺度特征融合模块与动态稀疏注意力机制, 显著提升了模型对微小目标及遮挡目标的特征表征能力; 通过采用 Version 数据集进行实验验证, 实验结果表明改进后模型的检测精度 ($mAP@0.5$) 达到 90.2%, 推理速度提升至 587.43 FPS, 较原 YOLOv9 的性能显著提升; 改进的 YOLOv9 算法在钢丝绳表面缺陷检测中仍能保持优异的检测性能, 为智能化钢丝绳表面断丝和磨损检测提供了可靠的技术解决方案。

关键词: 钢丝绳; 缺陷检测; YOLOv9; PGI; GELAN

Surface Defect Detection of Steel Wire Ropes Based on Improved YOLOv9 Algorithm

LI Lejun, LIANG Guowei

(State Power Investment Corporation Shanxi Electric Power Co., Ltd., Taiyuan 030001, China)

Abstract: To address the requirements for detection accuracy and real-time performance in identifying small-sized broken wires and wear defects on the surface of steel wire ropes, an algorithm based on YOLOv9 framework was optimized. By introducing the programmable gradient information (PGI) auxiliary supervision mechanism to enhance gradient information propagation, a generalized efficient layer aggregation network (GELAN) for efficient feature extraction was constructed, and a multi-scale fusion module along with a dynamic sparse attention mechanism was designed, significantly improving the model's feature representation capability for tiny and occluded targets. Experimental validation was conducted on the Version dataset, and the results demonstrate that the improved model achieves a detection accuracy ($mAP@0.5$) of 90.2% and an inference speed of 587.43 FPS, representing a significant advantage over the original YOLOv9 in performance. The improved YOLOv9 algorithm maintains an excellent detection performance for surface defects on steel wire ropes, providing a reliable technical solution for intelligent detection of broken wires and wear on steel wire rope surfaces.

Keywords: steel wire rope; defect detection; YOLOv9; PGI; GELAN

0 引言

钢丝绳作为起重、运输、建筑及海洋工程等领域重要的承载构件^[1], 其可靠性直接关系到各类机械设备的安全运行。然而, 在长期服役过程中, 由于机械磨损、疲劳载荷和环境影响等因素, 钢丝绳表面不可避免地会产生断丝、磨损、腐蚀等缺陷, 这些缺陷的积累将显著降低其承载能力并带来严重的安全隐患。传统的人工检测方法不仅效率低下, 且难以发现早期微观缺陷^[2], 这促使研究人员不断探索更高效、精确的检测技术。近年来, 随着无损检测技术^[3]、机器视觉^[4]和人工智能^[5]等

领域的快速发展, 基于电磁检测^[6]、超声检测^[7]、X射线检测^[8]、涡流检测^[9]、图像处理^[10]等新型检测方法为钢丝绳表面缺陷的智能识别提供了新的解决方案。

近年来, 钢丝绳表面缺陷的目标检测方法主要是基于深度学习和计算机视觉的技术。传统的机器视觉方法包括基于边缘检测和纹理分析的检测方法, 而新兴的检测方法包括 YOLO (You Only Look Once) 系列方法^[11]、Faster R-CNN 模型^[12]和 Transformer 架构^[13]等被广泛应用于断丝、磨损等缺陷的自动识别。文献^[14]通过构建全局精细化网络, 利用改进的 ECA 通道注意力-坐标注意力方法, 提高了钢丝绳小目标损伤识

收稿日期:2025-07-17; 修回日期:2025-08-04。

作者简介:李乐军(1986-),男,硕士,工程师。

引用格式:李乐军,梁国伟. 基于改进 YOLOv9 算法的钢丝绳表面缺陷检测[J]. 计算机测量与控制, 2025, 33(9): 56-62, 73.

别的精度。文献 [15] 提出一种改进的 YOLOv5s 模型用于矿井钢丝绳断丝检测, 通过 Swiener 滤波算法修复运动模糊图像并抑制噪声干扰, 结合 RFC3 轻量化模块和 CBAM-R 注意力机制增强小断口的特征提取能力和检测速度。文献 [16] 提出改进型 YOLOv8 检测算法, 通过在骨干网络中引入双层链路注意力机制增强图像分析与信息融合能力, 并嵌入双向特征金字塔网络提升缺陷特征提取的性能。文献 [17] 提出一种基于 YOLOv5 的曳引钢丝绳缺陷检测方案, 通过引入深度可分离卷积实现主干网络轻量化, 减少模型参数量。文献 [18] 提出一种基于 YOLOv5 的改进模型, 通过迁移学习方法提升小样本训练精度, 实现了钢丝绳表面小缺陷的高效精准检测。文献 [19] 提出一种基于 YOLOv5 改进的 TWRD-Net 算法, 通过设计轻量级 LW-C3 模块降低计算开销, 改进 CLW-FPN 结构增强缺陷特征提取能力。

基于以上分析, 由于 YOLO 模型的改进算法在工程设备的缺陷检测方面应用较少, 针对钢丝绳磨损和断裂检测精度较低和漏检的问题, 提出改进的 YOLOv9 模型, 通过在网络骨干部分引入 SKNet 注意力模块, 增强钢丝绳表面缺陷的特征提取能力, 在颈部的主分支上添加基于交叉注意力机制的 PSFM 模块, 进一步强化钢丝绳表面缺陷特征的特征能力, 并将损失函数替换为 EIoU, 提升模型在复杂环境下的检测性能。

1 YOLOv9 模型结构

YOLOv9 模型通过引入可编程梯度信息 (PGI, programmable gradient information) 与广义高效层聚合网络 (GELAN, generalized efficient layer aggregation network) 两大架构, 在降低推理成本的同时实现了检测精度的显著提升。如图 1 所示, PGI 作为辅助监督框架, 通过主分支、辅助可逆分支和多级辅助信息的协同作用解决深度网络训练问题: 主分支负责推理, 辅助可逆分支通过生成可靠梯度信息解决深度网络信息瓶颈问题, 多级辅助信息则整合不同预测头的梯度信息以控制主分支学习可规划的多级语义信息; 如图 2 所示, GELAN 架构基于梯度路径规划理念, 将其 CSPNet 和 ELAN 两种神经网络架构相融合, 借鉴了 CSPNet 的分割重组思想与 ELAN 的层级卷积处理模式, 该架构允许使用任意计算块作为基础模块, 通过对计算块组合方式的优化以及对网络深度的合理调控, 显著提升了参数利用率, 成功在维持轻量级特性的前提下, 实现了推理速度与检测精度之间的平衡, 为钢丝绳缺陷检测任务提供了高效且优质的解决方案。

如图 3 所示, YOLOv9 的网络结构^[21] 主要由骨干网络 (Backbone)、颈部网络 (Neck) 和头部网络 (Head) 三部分搭建而成。骨干网络作为模型的特征提




图 1 PGI 的网络结构




图 2 GELAN 的体系结构

取核心, 负责从输入图像中高效提取关键视觉特征, 为后续处理提供高质量的特征表示。颈部网络作为连接骨干网络和头部网络的桥梁, 通过多尺度特征融合和特征增强操作, 对骨干网络提取的原始特征进行优化整合, 提升特征的判别性和鲁棒性。头部网络则基于颈部网络输出的优化特征, 执行目标分类和定位任务, 最终实现




图 3 YOLOv9 的网络结构

图像中目标的准确检测与识别。

2 改进的 YOLOv9 算法

在 YOLOv9 网络架构中, 输入图像尺寸固定为 $640 \times 640 \times 3$ 。网络首层采用特殊的 Silence 操作模块, 该模块不执行任何计算操作, 仅保留原始输入图像数据, 为辅助分支提供直接的图像访问通道。特征提取核心采用改进的 RepNCSPELAN4 模块, 该模块创新性地融合了 CSPNet 的跨阶段连接优势和 ELAN 的长距离依赖建模能力, 其结构包含标准卷积模块和重参数化设计的 RepNCSP 子模块。其中, RepNCSP 由基础卷积模块和若干 RepNBottleneck 模块构成, 这些瓶颈模块采用残差连接结构, 其具体数量由网络宽度因子动态决定。

网络中的 CBLiner 模块整合了卷积 (Conv)、批归一化 (BN) 和 SiLu 激活函数, 通过特征拆分和可逆连接机制优化信息流动效率。SPPELAN 模块创新性地结合了空间金字塔池化 (SPP) 的多尺度特征提取能力和 ELAN 的上下文建模优势, 实现对不同尺度特征的全面捕获。特征融合环节采用 CBFuse 模块, 专门负责跨层

/跨分支特征的深度整合。此外, 网络还设计了多级辅助信息分支, 该分支与主干网络的特征金字塔各层级建立连接, 形成多层次的特征传递与增强机制, 显著提升了多尺度特征的代表能力。

2.1 钢丝绳表面缺陷的特征提取机制

为有效提升模型检测性能并增强其实际应用效能, 在模型的 backbone 部分中, 引入 SKNet 注意力模块, 旨在增强对钢丝绳缺陷的特征提取能力, 在 Neck 部分的主分支中, 添加 PSFM 模块, 该模块基于交叉注意力网络机制, 进一步强化骨干网络提取出的钢丝绳缺陷特征, 提高检测效率, 并将损失函数修改为 EIoU 以提升其在复杂环境下的检测性能。

在基于深度学习的目标检测任务中, 注意力机制主要作用于特征映射, 通过先后生成通道和空间两个互补的注意力权重。SKNet 是由南京理工大学 Li^[22] 团队提出的一种多分支动态注意力机制。

SKNet 的核心操作流程包括 Split、Fuse、Select 三个关键步骤, 其具体结构如图 4 所示。Split 操作首先将输入的特征图划分为多个分支, 然后进行不同维度的卷积操作, 以此捕获目标的多层次特征信息。Fuse 操




图4 改进 SKNet 结构

作则将不同分支提取的特征信息进行融合,并进行空间维度的全局平均,生成特征向量 S ,然后利用 F_{fc} 全连接层对特征向量 S 进行变换和降维,提取出关键的通道注意力特征,生成特征图 Z ,Fuse操作的公式如下。

对 U_1 、 U_2 两个特性图中相应的元素进行相加,得出 U :

$$U = U_1 + U_2 \quad (1)$$

将维度为 $C \times H \times W$ 的特征图转换为维度为 $C \times 1$ 的特征图 s :

$$s = F_{gp}(U) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U(i, j) \quad (2)$$

通过FC全连接提取通道注意力信息,得到特征图 z :

$$z = F_{fc}(s) = \delta(B(W_s)) \quad (3)$$

其中: δ 是ReLU函数, B 表示批量归一化, W_s 维度为 $d \times C$, d 为全连接后的特征纬度。为防止模型出现梯度消失或者梯度爆炸,做了如下改进:Select操作对通道注意力信号 Z 进行完全连接拓展,然后再通过Softmax运算得到权重向量 a 、 b 和 c ,由此得到对应的通道注意力信息 A_0 、 A_1 和 A_2 ,最后,将不同通道的注意力特征图谱进行融合,获得信道注意力特性图 A 。经过这些操作,不同尺度的卷积核在特征图上能够捕捉到更多的信息,加强了模型对小目标物体的感知能力,从而提高了对钢丝绳缺陷的检测精度。

2.2 钢丝绳表面缺陷的特征融合方法

为了确保模型在应对多样化的钢丝绳缺陷情况及复杂背景环境时仍能保持高检测效率,在网络的颈部结构中引入了PSFM(Profound Semantic Fusion Module)模块^[12]。该模块是一种基于交叉注意力机制的深层语义融合方法,旨在优化特征提取过程,提高模型对微小缺陷的感知能力,并增强鲁棒性,以适应复杂工况。

在目标检测任务中,特征融合对于模型的最终检测效果至关重要。传统的特征金字塔网络(FPN)和路径聚合网络(PAN)虽然能够实现不同尺度特征的融合,但在复杂背景下仍可能导致细粒度信息的丢失,进而影响模型的检测精度。PSFM模块通过引入交叉注意力机制,有效整合不同层级的特征信息,增强模型对目标区域的聚焦能力,并降低背景干扰的影响。

具体而言,在PSFM模块的运行过程中,首先利

用密集层(Dense Layer)对骨干网络提取的钢丝绳缺陷图像特征进行强化,以生成更具判别力的深层特征 F_{ir}^i 和 F_{ir}^i 。紧接着,运用一个投影函数(包含卷积操作与重塑操作)对增强后的特征进行转换,使其变为Key和Value,以适应交叉注意力机制的计算需求,具体转换过程如公式(4)~(5)所示:

$$K_x^i = \text{Reshape}(\text{Conv}_K^x F_x^i) \quad (4)$$

$$V_x^i = \text{Reshape}(\text{Conv}_V^x F_x^i) \quad (5)$$

其中: $x \in \{ir, vi\}$ 表示模态, $K_x^i \in R^{H_i \times W_i \times C_i}$ 表示Key, $V_x^i \in R^{H_i \times W_i \times C_i}$ 表示Value, $\text{Conv}(\cdot)$ 和 $\text{Reshape}(\cdot)$ 分别对核大小为 3×3 的卷积层和重塑操作, H_i 、 W_i 、 C_i 分别表示输入特征 F_x^i 的高度、宽度和通道数。

随后通过整合特征信息,充分利用多模态特征之间的互补特性,生成一个模态不变的查询向量,以减少模态差异对特征匹配的影响,并提升特征表达的一致性。如公式(6)所示:

$$Q^i = \text{Reshape}\{\text{Conv}[C(F_{ir}^i, F_{ir}^i)]\} \quad (6)$$

然后,根据公式(4)计算每个模态 x 的模态特定注意图 $A_x \in R^{H_i \times W_i \times H_i \times W_i}$:

$$A_x^i = \text{Softmax}(Q^i K_x^i) \quad (7)$$

将前层输出的特征张量与注意力权重矩阵进行逐元素相乘运算,以强化特征选择的有效性;紧接着将全局特征添加到另一个分支的原始特征中,并在通道维度上将生成的特征进行拼接,使钢丝绳缺陷图像的局部特征与全局特征进行融合,具体而言,全局特征用于构建空间注意力图谱,从而精准定位缺陷区域的空间分布,而局部特征则捕捉输钢丝绳缺陷表面的纹理细节,有助于增强模型对微小缺陷的识别能力;最后,将融合后的特征输入到卷积层中,以进一步提取深层语义信息,提升检测性能。具体结构如图5所示。

该过程可表述为公式(8):

$$F_{fu}^i = \text{Conv}\{C[F_{ir}^i \oplus \text{Reshape}(A_{ir}^i, V_{ir}^i), F_{ir}^i \oplus \text{Reshape}(A_{ir}^i, V_{ir}^i)]\} \quad (8)$$

2.3 EIou 损失函数

为了更有效地解决边界框回归任务中的样本失衡问题,引入了EIou(Enhanced IoU)损失函数。具体损失函数公式如下所示:

$$L_{EIou} = L_{IoU} + L_{dis} + L_{asp} = 1 - IoU + \frac{\rho^2(b, b^g)}{c^2} + \frac{\rho^2(w, w^g)}{c_w^2} + \frac{\rho^2(h, h^g)}{c_h^2} \quad (9)$$

其中: L_{IoU} 示预测框与真实框之间的重叠区域面积差值,用于度量二者的空间重叠程度; L_{dis} 为中心点距离损耗,用于衡量预测框与真实框中心点之间的欧几里得距离; L_{asp} 代表长宽比损耗,用以约束预测框的宽高与真实框保持一致; IoU 为交并比(Intersection over Union),即预测框与真实框重叠区域占联合区域的比




图 5 PSFM 模块架构

例： ρ 代表预测框和真实框中心点之间的欧几里得距离； b 和 b^{gt} 表示预测框和真实框； c 为最小封闭包围矩形的对角线长度，该封闭矩形将预测框和真实框同时包含在内，用以约束预测框的位置变化； c_w 、 c_h 为两个长方形的闭包宽度与高度； w 、 h 表示预测框的宽度和高度； w^{gt} 、 h^{gt} 表示真实框的宽度和高度。

3 实验及结果分析

3.1 实验数据集

Versions 数据集是一个面向工业检测场景的公开专业视觉数据集，原始数据共计 1 799 张，图像分辨率为 640×640 ，标签种类包括断裂、雷击、磨损 3 种类型，涵盖了不同场景、不同拍摄角度及不同尺度下的钢丝绳表面断丝、磨损等特殊缺陷。图 6 为数据集分布图。为增强模型的泛化能力并防止模型过拟合，检测实验在原始数据集的基础上，采用像素变换、几何变换等数据增强技术对图像进行扩充处理，包括随机翻转、亮度调




图 6 数据集分布图

整、平移旋转以及对比度增强等操作，使钢丝绳缺陷数据集的样本分布更加多样化。经过数据增强与清洗后，钢丝绳缺损的目标总框数为 3 040，其中 1 260 张有效图像，其中断裂框数为 1 235；雷击痕迹框数为 750；磨损框数为 1 055，极大丰富了模型的训练样本。

3.2 实验环境

本实验在 Ubuntu 21.04 操作系统环境下进行，硬件平台采用 AMD Ryzen 7 7900H 处理器、NVIDIA GeForce RTX 4070 显卡。实验所使用的深度学习框架为 PyTorch 2.4.0，编程语言为 Python 3.8.10，同时集成 CUDA 和 CUDNN 作为 GPU 加速库，以支持大规模数据训练和复杂网络计算。

网络训练过程进行 300 次迭代，每批次输入数据量大小为 16，将输入图像统一转化成大小为 640×640 的图像并归一化，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 0.005。初始分类损失权重为 0.5，初始边界框损失权重为 0.05，置信度损失权重为 1。

3.3 模型训练

本次实验统一设定图像输入分辨率为 640×640 像素，批次处理量为 16，并规划了 300 轮次的模型迭代训练，同时保持其他参数沿用默认设置，以确保实验的一致性和可复现性。图 7 展示了模型训练过程中各项指标的变化趋势。随着训练轮次的增加，边界框回归损失 (box_loss) 和目标置信度损失 (obj_loss) 均呈现明显的下降趋势并最终趋于稳定，这表明模型在目标定位和存在性判断方面的能力持续提升。与此同时，准确率 (Precision)、召回率 (Recall) 和平均精度 ($mAP@0.5$) 等关键性能指标均保持稳步上升的态势，进一步验证了模型训练的有效性。其中，box_loss 曲线的持续下降反映了预测边界框与真实标注框的匹配精度不断提高，obj_loss 的收敛则说明模型对目标存在的判断越来越准确。这些指标协同优化的趋势充分表明：模型在训练过程中学习到了有效的钢丝绳缺陷目标的特征表示，不仅能够精确地定位钢丝绳缺陷目标的位置，还能可靠地识别钢丝绳缺陷目标类别，最终达到了较高的检测精度。各项评估指标的一致性变化证明训练过程稳定，模型具备良好的泛化能力。

4 实验结果评估分析

4.1 对比实验

为验证改进算法对检测性能的提升效果，实验采用相同数据集对 SSD、YOLOv5、YOLOX、YOLOv8、YOLOv9 及本文算法进行训练，并使用统一测试集开展性能评估。

对比实验结果如表 1 所示：本文算法在钢丝绳缺陷




图 7 改进 YOLOv9 算法的训练相关曲线

检测任务中,准确率达到 91.3%,召回率为 87.1%,平均检测精度为 90.2%。从整体趋势来看,从 SSD 到 YOLOv9 系列,算法的准确率(P)、召回率(R)和 $mAP@0.5$ 指标均呈现逐步提升的态势,反映了钢丝绳缺陷目标检测技术的持续进步。具体来看,YOLOv9 相较于前代 YOLOv8 在准确率上提升了 1.2%,但在召回率上略有下降,这表明 YOLOv9 侧重于保证钢丝绳目标检测结果的准确性。值得注意的是,本文提出的方法在所有指标上均显著优于其他算法,特别是 $mAP@0.5$ 达到 90.2%,比最优的 YOLOv9 高出 2.7 个百分点,同时在准确率和召回率上也分别领先 2.6% 和 2.9%,展现了其网络综合性能的优势。YOLOX 和 YOLOv5 的表现较为接近,而 SSD 作为较早期的算法,各项指标明显落后于基于 YOLO 系列的方法,这凸显了单阶段检测器架构的演进带来的性能提升。

表 1 对比实验结果

算法	$P/\%$	$R/\%$	$mAP@0.5$
SSD	78.8	80.3	79.4
YOLOv5	85.6	83.9	84.3
YOLOx	85.8	85.1	85.5
YOLOv8	87.5	85.3	87.1
YOLOv9	88.7	84.2	87.5
本文方法	91.3	87.1	90.2

4.2 消融实验

为验证 SKNet 注意力机制、PSFM 模块及 EIoU 损失函数对检测性能的独立贡献,本研究在对比实验基础上开展消融实验。实验采用模块化对比设计,通过逐步添加改进模块的方式,系统分析各组件对模型性能的影响。

消融实验结果如表 2 所示,其中“√”表示对应模块的添加状态。

表 2 消融实验结果

YOLOv9	SKNet	PSFM	EIoU	$P/\%$	$R/\%$	$mAP/\%$
√				88.7	84.2	87.5
√	√			89.6	85.3	88.9
√		√		89.2	86.1	88.5
√			√	89.9	85.8	89.1
√	√	√	√	91.3	87.1	90.2

消融实验旨在评估 SKNet 注意力机制、PSFM 模块、EIoU 损失函数及组合优化方案对检测性能和计算效率的独立贡献。通过分析各模块在特征增强、计算复杂度优化和检测精度提升方面的作用,确定最优改进组合以实现模型性能与效率的平衡。

表 2 的消融实验系统地验证了各改进模块对 YOLOv9 性能的贡献。基础 YOLOv9 模型取得了 88.7% 的准确率、84.2% 的召回率以及 $mAP@0.5$ 达到 87.5%。单独引入 SKNet 注意力机制后,三项指标分别提升 0.9%、1.1% 和 1.4%,表明 SKNet 注意力机制对钢丝绳缺陷特征选择的有效性。PSFM 模块的加入使得准确率提升 0.5%,而召回率也增加了 1.9%,突显其在钢丝绳多尺度缺陷特征融合方面的优势。EIoU 损失函数使 $mAP@0.5$ 提升 1.6 个百分点,验证了其在边界框回归中的优越性。值得注意的是,当 SKNet、PSFM 和 EIoU 共同作用时,模型性能达到最优(P : 91.3%, R : 87.1%, mAP : 90.2%),且提升幅度超过各模块单独作用时的简单累加,说明这些改进具有良好的协同效应。实验结果充分证明了每个模块的有效性,以及它们

组合使用的必要性,为模型性能的全面提升提供了有力支撑。

4.3 对比实验

本研究通过可视化对比分析,系统评估了经典 YOLOv9 算法与改进算法在钢丝绳表面缺陷检测中的性能差异。如图 8 所示,改进模型通过引入 PGI 辅助监督机制、GELAN 特征提取网络和多尺度融合模块,显著提升了缺陷特征的特征能力。特征激活图可视化结果表明,改进模型对微小断丝和磨损缺陷的特征响应更加清晰和集中,特别是在低对比度区域仍能保持稳定的激活强度。这种改进主要得益于 PGI 机制提供的多层次监督信号,以及 GELAN 网络增强的非线性特征提取能力,使得模型能够捕捉到更细微的缺陷特征差异。




图 8 改进的 YOLOv9 算法的可视化对比图

在特征融合方面,本文提出的特征金字塔空间融合模块 (PSFM) 构建了高效的多尺度特征交互架构。可视化结果显示,该模块能够有效整合钢丝绳缺陷目标不同层级的语义信息和空间细节,显著提升了模型对多尺度缺陷的适应能力。具体而言,对于大面积的磨损缺陷,高层特征提供了准确的语义定位;而对于细小的断丝缺陷,低层特征保留了必要的纹理细节。检测效果对比表明,改进算法在复杂工业背景下展现出更优越的性能:一方面,在密集分布缺陷场景中,模型能够有效区分相邻缺陷并减少粘连误检;另一方面,对于部分遮挡的缺陷,改进模型凭借更精准的边界框回归,实现了更高完整度的缺陷轮廓捕捉。

从缺陷类别的特异性表现来看,改进模型在断裂与雷击痕两类缺陷上的检测效果提升最为显著。对于断裂缺陷,改进模型能够准确识别出其他算法容易漏检的微小裂纹;对于雷击痕这类形态不规则的缺陷,模型展现出更强的形状适应能力。这些改进主要源于 PSFM 模块带来的多尺度特征互补优势,以及 EIou 损失函数对不规则边界框的优化效果。综合可视化分析结果,本文

提出的改进方案不仅提升了模型的整体检测精度,更重要的是增强了算法在工业复杂场景下的鲁棒性和实用性,为钢丝绳表面缺陷的自动化检测提供了更可靠的技术方案。

5 结束语

针对钢丝绳表面断丝和磨损等微小缺陷的检测需求,本文提出一种基于改进 YOLOv9 的轻量化缺陷检测算法。通过引入 PGI 辅助监督机制和 GELAN 特征提取架构,结合多尺度特征融合模块 (MSFM) 与动态稀疏注意力机制 (DSAM),显著提升了模型对钢丝绳表面缺陷的特征表征能力。实验结果表明,改进后的模型在保持轻量化的同时 (参数量仅 9.2 M),检测精度 ($mAP@0.5$) 达到 90.2%,较基准模型提升 2.7 个百分点,且推理速度达到 210 FPS,满足工业实时检测需求。

在后续研究中,可考虑将 X 射线成像等多模态数据融合到检测框架中,以提升对内部钢丝绳缺陷的检测能力;同时需要构建包含更多工况的工业级钢丝绳缺陷数据集,进一步验证算法在复杂工业环境下的泛化性能,这些改进将有力推动该技术在矿山、电梯等关键领域的工程应用。

参考文献:

- [1] 刘大平,梅一,朱栋,等.输电线路张力架线牵引用钢丝绳断丝检测系统研究[J].电力设备管理,2023(1):295-297.
- [2] 王永垚,李芳,郭爱军,等.钢丝绳损伤电磁检测实验系统及其应用分析[J].山西能源学院学报,2023,36(4):100-102.
- [3] 许钟奇,杨建华,李尚袁,等.钢丝绳无损检测信号处理算法的进展[J].无损检测,2023,45(11):72-79.
- [4] 姜泓宇,董增寿,贺之靖.基于机器视觉的钢丝绳表面缺陷检测[J].太原科技大学学报,2023,44(5):434-439.
- [5] 王振滨.基于深度学习的钢丝绳表面缺陷检测研究[D].中国矿业大学,北京,2024.
- [6] 张恩超.钢丝绳多尺度缺陷定量磁检测技术研究[D].哈尔滨工业大学,哈尔滨,2021.
- [7] 李宁,张海月,高树灵,等.基于超声能量扩散的 CFST 界面剥离损伤检测方法验证[J].工程力学,2023,40(1):111-120.
- [8] 彭放,刘甜甜,苏江文,等.基于 X 射线无损探伤的输电线路耐张线夹缺陷检测[J].机械制造与自动化,2024,53(4):264-270.
- [9] 刘奇,岳立柱.应用 PDCA 循环提升涡流探伤机检测稳定性[J].现代制造工程,2020(7):77-82.

(下转第 73 页)