文章编号：1003－1251(2026)05－0025－06

基于 YOLOv8n-AIC 的钢丝绳表面缺陷检测算法

王 斌，蒋 强，李婷雪

（沈阳理工大学 自动化与电气工程学院，沈阳 110159）

摘 要：钢丝绳作为工业关键承重部件，其表面缺陷呈小目标、多尺度、低对比度的特点。针对现有检测算法精度低、计算量大、效率低的问题，提出一种改进 YOLOv8n 的算法 YOLOv8n-AIC。该算法融入轻量化下采样模块 ADown 优化 YOLOv8n 主干网络，减少参数量；设计注意力模块 iEMA 并引入主干网络，消除通道冗余，增强多尺度特征提取能力；采用轻量级跨尺度特征融合模块（cross-scale feature fusion module，CCFM）改进 YOLOv8n 颈部网络形成 CF-Neck 结构，提升算法对检测目标尺度变化的适应能力。实验结果表明，针对钢丝绳表面缺陷数据集，改进算法的 mAP@0.5 达 95.9%。相比 YOLOv8n 算法，mAP@0.5 提升 2.6%，召回率提高 2%，参数量和计算量分别降低 42.9%、25.9%，实现了轻量化，降低了计算成本，为钢丝绳缺陷快速精准检测提供了有效的解决方案。

关 键 词：钢丝绳表面缺陷；ADown 模块；跨尺度特征融合模块；小目标检测；轻量化

中图分类号：TP391.4 **文献标志码**：A **DOI**：10.3969/j.issn.1003－1251.2026.05.004

Steel Wire Rope Surface Defect Detection Algorithm Based on YOLOv8n-AIC

WANG Bin，JIANG Qiang，LI Tingxue

（Shenyang Ligong University，Shenyang 110159，China）

Abstract：Steel wire ropes，as critical industrial load-bearing components，exhibit surface defects characterized by small targets，multiple scales，and low contrast. To address the issues of low precision，high computational load，and inefficiency with existing detection algorithms，an improved YOLOv8n algorithm，termed YOLOv8n-AIC，has been proposed. This algorithm incorporates ADown module to optimize YOLOv8n backbone network，reducing the number of parameters. An iEMA module is developed and introduced to eliminate channel redundancy，enhancing the capability of multi-scale feature extraction. Additionally，a cross-scale feature fusion module（CCFM）is employed to modify YOLOv8n neck network to form a CF-Neck structure，improving the adaptability of the algorithm to target scale variations and the ability in detecting small targets. Experimental results on a steel wire rope surface defect dataset demonstrate that a mean Average Precision（mAP）at IoU 0.5 of 95.9% is obtained for YOLOv8n-AIC. Compared to the original YOLOv8n algorithm，mAP@0.5 and recall rate increases by 2.6% and 2%；the number of parameters and computational load decrease by 42.9% and 25.9%，respectively. It results in a lightweight model that reduces computational costs，providing a feasible solution for rapid and accurate detection of steel wire rope defects.

Key words：steel wire rope surface defects；ADown module；cross-scale feature fusion module；small target detection；lightweight

收稿日期：2025－03－18

基金项目：辽宁省教育厅高等学校基本科研项目（LJ21241014452）

作者简介：王斌（1997—），男，硕士研究生；蒋强（1974—），通信作者，男，教授。

钢丝绳凭借良好的弯曲性能、高承载能力、轻质及结构多样等优势,广泛应用在矿井牵引与承载作业中。工作时,钢丝绳长期露天暴露,易受雨水侵蚀、粉尘附着,以及异常摩擦、碰撞、冲击和挤压等复杂因素的影响,导致磨损、断丝等不可逆损伤,严重威胁使用安全[1]。相关统计显示,在强度和可靠性仍满足要求时,约 70% 钢丝绳被提前更换。如果能够实现钢丝绳表面缺陷快速精准的检测,对提升作业安全性与资源的利用效率具有重要作用。

基于漏磁原理的钢丝绳无损检测技术[2]是传统钢丝绳检测手段之一。然而,该技术存在成本较高的问题,且漏磁检测仪器设备复杂,需专业人员操作,对操作人员的技术要求较高,限制了其在一些场合的广泛应用。同时,漏磁检测深度有限,难以探测钢丝绳深层次或微小缺陷,易造成漏检。人工目视法作为工程中常用的简易方法,存在检测耗时久,受主观因素影响大的弊端[3],对于复杂、微小或隐蔽缺陷常难以察觉,检测效率低,无法实现高精度、长时间的监测。

伴随人工智能技术的飞速进步,基于深度学习的目标检测方法在各领域广泛应用。以 Faster R-CNN[4]为代表的两阶段检测算法,主要涵盖特征提取及候选框分类回归,该架构赋予其较高检测精度。以 YOLO[5]系列及单次多框检测器 SSD[6]为代表的一阶段检测算法通过单一阶段即可同步完成特征提取与分类,实现了更快的检测速度。随着 YOLO 系列算法的演进,其网络结构与数据融合持续优化。YOLOv10[7]引入双重分配策略,摆脱了对非极大值抑制(NMS)技术的依赖;YOLOv11[8]采用 C3K2 和 C2PSA 模块,更高效地提取和融合目标特征。上述最新检测算法虽理论性能有所提升,但在工业领域的实际应用中案例较少,成熟度与稳定性尚未得到广泛的实践验证。

目标检测领域已有诸多研究成果是针对早期不同版本 YOLO 算法的改进。文献[9]将 YOLOv3 的骨干网络 Darknet-53 替换为轻量级网络 MobileNet,提升了模型的检测速度。文献[10]提出了一种改进 YOLOv5s 的小目标缺陷检测方法,在主干网络引入全维动态卷积(ODConv),采用边界框损失函数 WIoU 并增加了检测头,提升了算法对各类缺陷的检测精度。文献[11]将 CBAM 与 TPH 模块集成至 YOLOv5,改进后的模型展现出较好的检测性能。文献[12]基于 YOLOv7 提出了检测算法 ECC-YOLO,通过引入特征增强模块 ConvNeXt,融合深度可分离卷积与大核卷积,增强了算法对细小缺陷的特征提取能力;同时设计了 C2fFB 与 MPCE 模块,降低了模型的计算量与参数量,提升了检测效率。上述改进算法虽取得了一定成效,但针对特定目标仍存在计算量与参数量较大、检测精度不足的问题,模型结构与推理速度有待进一步优化。

鉴于 YOLOv8 拥有更长的市场验证周期、更完善的生态支持,在工业应用中具备更高成熟度与稳定性,本文提出一种基于 YOLOv8n 的改进算法 YOLOv8n-AIC。该算法旨在增强模型对特征信息的提取能力,在提升小目标检测精度的同时,降低参数量与计算成本。具体改进内容如下。

1)将轻量化下采样模块 ADown 融入主干网络,显著降低参数量,同时提高小目标检测精度。

2)设计注意力模块 iEMA,并引入到主干网络,有效去除通道内冗余信息,增强模型稳定性,提升其对多尺度特征的提取能力。

3)为增强模型适应目标尺度变化,特别是针对小尺度对象的检测能力,采用轻量级跨尺度特征融合模块(cross-scale feature fusion module, CCFM)改进 YOLOv8n 的颈部网络,构建 CF-Neck 结构。通过减少计算量,使模型在维持高效性的同时更好应对尺度变化带来的挑战,进而提升模型在复杂场景下的检测性能。

1 YOLOv8n-AIC 检测算法

本文选定 YOLOv8n 作为基础预训练模型,优化和改进后的 YOLOv8n-AIC 算法结构如图 1 所示。图 1 中,Backbone、CF-Neck 以及 Head 分别对应模型的主干部分、颈部和头部。其中,Conv 代表卷积层;C2f 模块实现对特征图跨阶段的部分链接和融合;Concat 表示无参数的张量操作;SPPF 是空间金字塔池化模块;iEMA 是融合跨空间学习的多尺度注意力机制 EMA[13]与倒置残差结构 iRMB[14]所提出的注意力模块;Upsample 表示上采样操作;Detect 表示检测头。

1.1 轻量化下采样模块 ADown

本文所采用的钢丝绳数据集中,存在一定比例尺度仅为几毫米的微小缺陷。在检测过程中,这类微小缺陷极易被忽略,难以精准识别。传统的卷积神经网络(CNN)为达到可接受的准确度,通常需要大量参数量与计算量,提升了计算复杂度,不利于高效、低成本地开展检测任务。

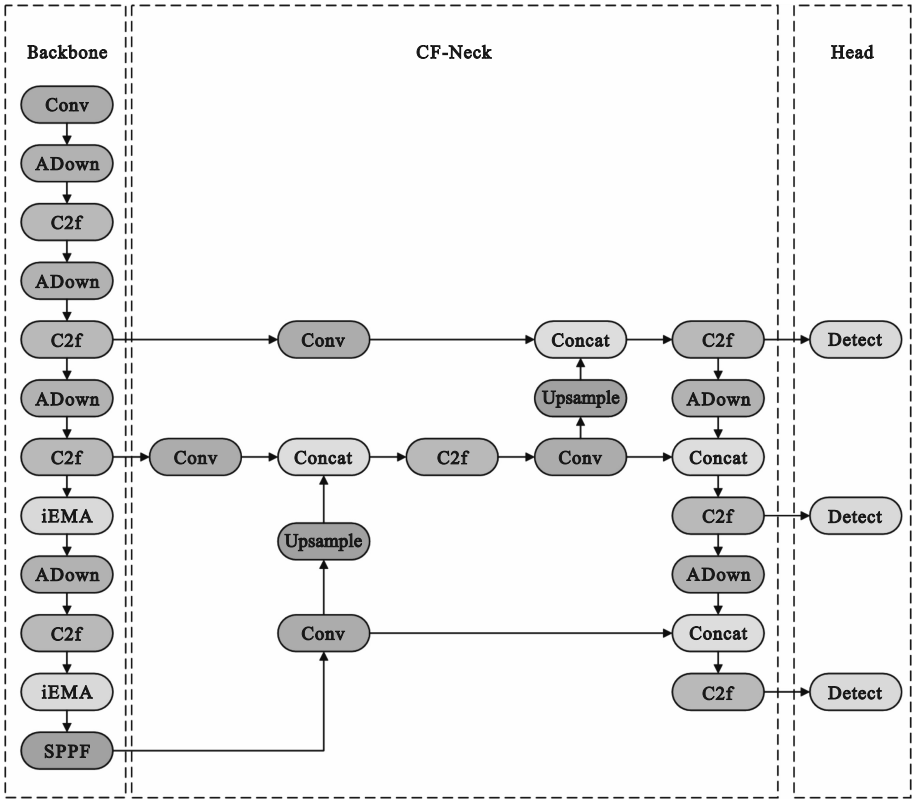


图 1　YOLOv8n-AIC 网络结构

Fig. 1　YOLOv8n-AIC network architecture

为此,本文将 ADown 模块融入主干网络,利用其自适应机制,根据输入特征图不同区域信息的变化,动态确定特征传输路径,有效保留关键的小尺度特征,提升检测精度。该模块结合多尺度特征融合策略,采用深度可分离卷积,在整合多尺度特征的同时,降低参数数量与计算复杂度,实现了参数量减少与图像特征捕捉能力增强的双重目标[15]。ADown 模块结构如图 2 所示。该模块首先进行步幅为 1 的(2×2)平均池化(AvgPool2d),高效保留空间细节,精准捕捉细粒度特征,防止降采样时小目标信息丢失;而后特征图进入通道切分模块(Chunk),将通道维度均分为两部分,每部分通道数减半以降低单路径参数量,再分别对两部分特征图进行处理以增强特征的表达能力。一部分先通过最大池化(Maxpool2d)突出小目标显著特征,再用一维卷积提取特征;另一部分直接卷积提取局部特征并适度降采样减少计算量。最后,沿通道维度拼接这两部分特征图,生成富含上下文细节的特征图,为后续网络提供更全面多元的特征信息。图 2 中:变量 k 表示卷积核的大小,$k=3$ 表示卷积核是一个 3×3 的矩阵;变量 s 表示卷积核在输入特征图上滑动的步长,$s=2$ 表示卷积核每次滑动 2 个像素;变量 p 表示在输入特征图的边界上添加的额外像素,$p=0$ 表示不填充。

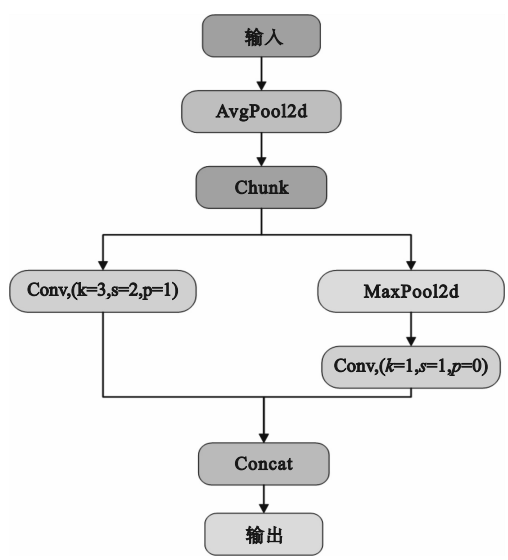


图 2　ADown 模块结构

Fig. 2　Structure of ADown module

1.2　iEMA 模块

为增强模型对局部纹理特征的捕获与利用能力,提升缺陷检测的准确性与鲁棒性,本文提出 iEMA 模块,并将其嵌入 YOLOv8n 主干网络的第 7 层和第 10 层,iEMA 模块结构如图 3 所示。其中,EMA 通过多分支结构、全局池化及空洞卷积

捕获多尺度信息,在细节与小目标建模上表现突出,但计算开销较高[16];iRMB 是一种倒置残差结构,其引入扩展窗口多头自注意力(EW-MHSA),具备全局建模能力,但在信息压缩阶段易丢失关键信息[17]。iEMA 模块融合了 EMA 与 iRMB 的优势,可实现特征通道间的上下文交互与空间细节的精细化建模。

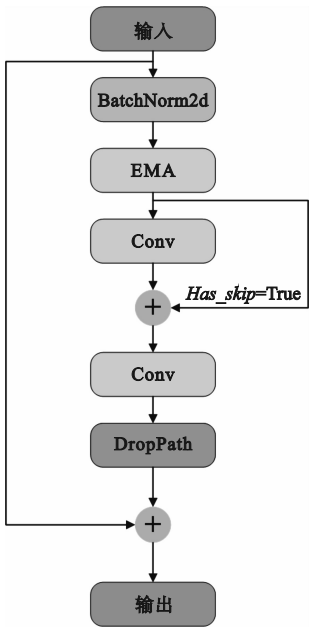


图 3 iEMA 模块结构

Fig. 3 Structure of iEMA module

模块输入特征首先经二维批量归一化(BatchNorm2d)处理,以稳定特征分布、加速模型收敛并缓解内部协变量偏移。随后进入 EMA 注意力层,融合 EMA 的多尺度建模能力与 iRMB 的全局交互能力,通过跨空间学习优化多头注意力机制,在避免信息丢失的同时整合空间特征、滤除冗余信息。依次经过的两个卷积层中,第一层用于变换特征维度,第二层用于提取深层语义特征。通过引入随机深度(DropPath),在训练过程中以一定概率随机丢弃该分支路径,起到正则化作用,防止模型过拟合并增强泛化性能。当启用残差连接时(*Has_skip* = True),将输入特征与 DropPath 后的输出进行逐元素相加,得到模块最终输出结果。该设计解决了 iRMB 在信息压缩阶段关键信息易丢失的问题,同时弥补了 EMA 计算开销较高的不足,在轻量结构下显著提升了特征提取效率与复杂场景下的模型鲁棒性,尤其增强了对钢丝绳表面缺陷局部纹理细节的检测能力。

1.3 CF-Neck 网络结构

CCFM 作为 RT-DETR 框架的核心创新点[18],该模块运用独特策略,将不同尺度的特征信息有效融合,显著增强了模型对目标特征的层次化提取能力,有效提升了模型对尺度变化的鲁棒性,尤其提升了小尺度目标检测的精度。

在 YOLOv8n-AIC 算法中,颈部网络借鉴了 CCFM 模块的原理构建了 CF-Neck 网络结构,该结构采用了多尺度特征融合策略,将来自不同层级的特征图经过 Conv 处理后再以 Concat 的方式拼接,使高层特征的语义信息和低层特征的细节信息能在相同尺度上实现融合。随后,运用自上向下路径聚合的方法,将较深层的特征图通过双线性插值上采样到与浅层特征相同的分辨率,再进行拼接,以此增强对小目标的检测能力。最后,借助 ADown 模块下采样浅层特征,使其与更深层特征在同一尺度上结合,从而融合更多的高层语义。这种跨层连接的架构,在显著降低模型参数量的同时,增强了模型对不同尺度钢丝绳缺陷的检测能力。

2 实验及结果分析

2.1 实验环境

本文模型训练平台硬件配置如下:中央处理器选用 Intel(R) Core(TM) i5-13500HX;图形处理器为 NVIDIA GeForce RTX 4060 Laptop GPU;显存容量达 24 GB。

软件配置如下:操作系统为 Windows 11;深度学习框架基于 Pytorch-2.1.0 + cu118 搭建;开发语言为 Python 3.9;计算架构适配 CUDA 11.8。模型训练过程中的各项训练参数设置如表 1 所示。

表 1 训练参数

Table 1 Training parameters

训练参数	数值
初始学习率	0.01
优化器	SGD
优化器动量	0.937
输入图像分辨率/px	640 × 640
工作线程	8
批量大小	8
训练周期	300

2.2 实验数据集

本文采用 roboflow 网站公开的钢丝绳缺陷数据集开展研究。该数据集涵盖 1 318 张图像,

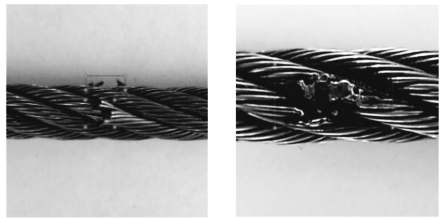
共涉及断丝(break)和磨损(thunderbolt)两类缺陷。为满足模型训练与评估需求,数据集以约8:2的比例被划分为训练集与验证集,其中训练集包含 1 054 张图像,验证集包含 264 张图像。数据集信息列于表 2,两类缺陷样本示例如图 4 所示。

表 2　数据集信息

Table 2　Dataset information

序号	类别	数据增强技术	图像数	框数	标注工具
1	断丝	几何变换、颜色变换等	767	822	LabelImg
2	磨损		584	690	

为全面评估模型针对钢丝绳缺陷的检测性能,本文选用准确率(Precision)、召回率(Recall)、平均精度均值(mAP@0.5)、模型参数量(Params)及浮点计算量(GFLOPs)等指标。



(a) 断丝　　(b) 磨损

图 4　两类缺陷样本示例

Fig. 4　Examples of two types of defect samples

2.3　实验结果分析

2.3.1　消融实验

为定量验证改进算法的有效性,本文在统一的实验环境及数据集上,以 YOLOv8n 算法为基准设计了 6 组消融实验。实验分别针对引入 ADown 模块、iEMA 模块、CF-Neck 结构、ADown-iEMA 组合以及 ADown-iEMA-CF-Neck 整合结构的模型展开。各消融实验结果汇总于表 3,可直观对比分析各改进组件对模型性能的影响。

表 3　消融实验结果

Table 3　Results of the ablation experiments

序号	YOLOv8n	ADown	iEMA	CF-Neck	Precision	Recall	mAP@0.5	Params/10^6	GFLOPs
1	√				0.918	0.899	0.933	3.01	8.1
2	√	√			0.933	0.919	0.954	2.59	7.2
3	√		√		0.943	0.920	0.942	3.09	8.2
4	√			√	0.938	0.921	0.950	1.96	6.6
5	√	√	√		0.947	0.925	0.950	2.68	7.4
6	√	√	√	√	0.923	0.919	0.959	1.72	6.0

从表 3 的实验结果可知,采用单一改进策略对 YOLOv8n 算法进行优化时,模型的检测精度相较于原网络有一定程度的提升。单独融合 ADown 模块后,模型的参数量和计算量均有所降低,同时 mAP@0.5 值提升了 2.1%,表明 ADown 模块在降低模型复杂度和计算成本的同时,有效提高了检测精度。单独采用 CCFM 模块改进 Neck 网络形成 CF-Neck 结构后,参数量和浮点计算量分别下降了 34.9% 和 18.5%,mAP@0.5 提升了 1.7%,说明 CF-Neck 网络结构不仅增强了模型整合多尺度特征的能力,优化了检测性能,还显著提升了模型的计算效率和资源利用率。单独引入 iEMA 注意力模块后,参数量和浮点计算量基本保持不变,mAP@0.5 提升了 0.9%,表明 iEMA 模块能够更有效地捕捉和融合特征信息,提升模型的特征表达能力。

当采用两种或以上改进策略优化 YOLOv8n 算法时,模型的检测精度进一步提升,实现了轻量化。同时引入 ADown 模块和 iEMA 模块后,mAP@0.5 较原网络提升了 1.7%,参数量和浮点计算量分别下降了 10.9% 和 0.8%。尽管与单独引入相应模块相比,参数量和浮点计算量略有增加,但精确率和召回率显著提高。将 ADown 模块、iEMA 模块和 CF-Neck 结构融合到 YOLOv8n 算法中,mAP@0.5 达到最高值 0.959,较原网络提升了 2.6%,参数量和浮点计算量分别下降了 42.9% 和 25.9%。在消融实验中,该改进模型的整体检测精度优于其他对比模型,且实现了更高程度的轻量化。

综上所述,本文提出的改进算法 YOLOv8n-AIC 在保持模型轻量化的同时,增强了对尺度变化的鲁棒性和对小尺度目标的检测能力,显著提高了检测精度。

2.3.2　对比实验

为全面评估改进后算法的检测性能,将改进算法与其他主流的目标检测算法在本文所采用的数据集上开展对比实验,实验结果汇总于表 4。

由表 4 数据可知,改进算法在模型参数量与计算量方面呈现显著下降趋势,同时精确率与 mAP@0.5 均达到最高水平,其中 mAP@0.5 的值相较于 YOLOv5s、YOLOv7-tiny 和 YOLOv8n 分别提升了 1.2%、7.5% 和 2.6%。

由此可见,在钢丝绳表面缺陷检测任务中,改进算法不仅达成了高精度检测,还出色地维持了模型的轻量化特性。

表 4 不同算法的对比实验结果

Table 4 Comparison of experimental results with different algorithms

算法	Precision	Recall	mAP@0.5	Params/10^6	GFLOPs
Faster R-CNN	0.571	0.858	0.821	28.29	940.94
SSD	0.907	0.699	0.838	23.87	60.95
YOLOv5s	0.921	0.936	0.947	7.02	15.80
YOLOv7-tiny	0.882	0.866	0.884	6.02	13.20
YOLOv8n	0.918	0.899	0.933	3.01	8.10
本文算法	0.923	0.919	0.959	1.72	6.0

2.4 实验结果示例

为直观呈现改进算法 YOLOv8n-AIC 的检测成效,本文从数据集两类缺陷里各随机抽取一张图像,分别使用原始算法 YOLOv8n 与改进算法 YOLOv8n-AIC 进行检测,结果如图 5 所示。图 5(a)列呈现的是原始图像,5(b)列展示的是原始算法 YOLOv8n 的检测结果,5(c)列则为本文改进算法 YOLOv8-AIC 的检测结果。

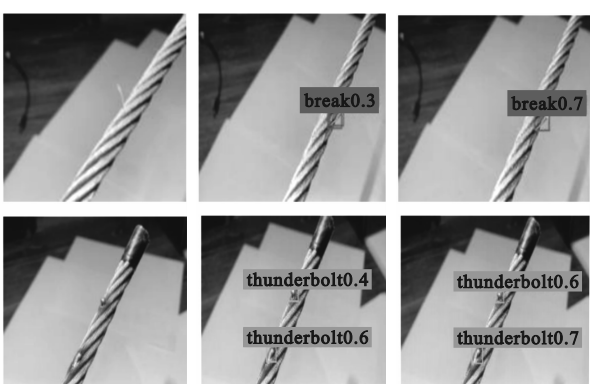


图 5 检测结果

Fig. 5 Detection results

从图 5 中能够清晰观察到,相较于原始算法,本文提出的 YOLOv8n-AIC 算法在小目标检测方面展现出更为突出的性能,检测精度显著提升,且能高效提取不同尺度的语义信息。

3 结论

针对小目标检测精度欠佳且计算量过大的问题,本文提出了一种适用于钢丝绳表面缺陷检测的算法 YOLOv8n-AIC。该算法通过融合轻量化下采样模块 ADown 对主干网络进行改进与优化,在降低参数量的同时提升了对微小缺陷的检测能力。同时,设计并引入了 iEMA 注意力模块、CF-Neck 结构,显著增强了模型对尺度变化的适应性,能够更有效地应对目标尺度变化带来的挑战。

实验结果表明,改进后的模型在钢丝绳表面缺陷数据集上表现出色,mAP@0.5 达到 0.959。相较于原 YOLOv8n 模型,mAP@0.5 提升了 2.6%,召回率提高了 2%,参数量与计算量分别降低了 42.9% 和 25.9%。上述改进使算法更易于在移动端部署。

参考文献(References):

[1] 魏明江,战卫侠,尚允坤,等. 钢丝绳断丝漏磁场分布规律三维动态仿真分析[J]. 工矿自动化,2025,51(2):148-154,162.
Wei M J,Zhan W X,Shang Y K,et al. Three-dimensional dynamic simulation analysis of magnetic flux leakage distribution in broken strands of wire ropes[J]. Journal of Mine Automation,2025,51(2):148-154,162. (in Chinese)

[2] 赵旭,朱姿娜. 基于漏磁原理的钢丝绳无损检测励磁结构设计与优化[J]. 仪表技术与传感器,2023(4):31-35,41.
Zhao X,Zhu Z N. Design and optimization of excitation structure for non-destructive testing of steel wire rope based on leakage magnetism[J]. Instrument Technique and Sensor,2023(4):31-35,41. (in Chinese)

[3] Zhang J W,Wang S L. Nondestructive testing of wire ropes based on image fusion of leakage flux and visible light[J]. Journal of Failure Analysis and Prevention,2019,19(2):551-560.

[4] Ren S Q,He K M,Girshick R,et al. Faster R-CNN:towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(6):1137-1149.

[5] Zheng J H,Wang D Y,Geng Z X. Real-time detection of safety hazards in coal mines utilizing an enhanced YOLOv3 algorithm[J]. Traitement Du Signal,2023,40(4):1565-1572.

[6] Liu W,Anguelov D,Erhan D,et al. SSD:single shot MultiBox detector[M]//Computer Vision-ECCV 2016. Cham:Springer International Publishing,2016:21-37.

[7] 刘印,龚长友,徐国栋. 基于改进 YOLOv10 的轻量化目标检测算法[J]. 自动化与信息工程,2025,46(1):29-35.
Liu Y,Gong C Y,Xu G D. Lightweight object detection algorithm based on improved YOLOv10[J]. Automation & Information Engineering,2025,46(1):29-35. (in Chinese)

(下转第 40 页)