

DOI:10.19651/j.cnki.emt.2519041

基于 YOLOv11 的煤矿用钢丝绳表面 缺陷检测算法研究*

郭旭鹏 董立红 秦 映

(西安科技大学人工智能与计算机学院 西安 710054)

摘要: 针对煤矿钢丝绳表面缺陷检测中存在的小目标尺度差异大、复杂背景干扰强等问题,提出一种基于改进 YOLOv11 的深度学习检测算法。首先,设计感受野注意力特征提取模块 C3k2_RFACConv,通过动态调整卷积核权重增强复杂纹理下的特征提取能力;其次,在特征融合层引入可变形大核注意力机制 D-LKA,结合大感受野与可变形卷积的优势,精准聚焦缺陷区域;此外,采用 DySample 上采样优化以抑制背景噪声干扰,减少小目标特征丢失;最后,提出 Inner-WIoU 损失函数优化边界框回归,提升不规则缺陷的定位精度。实验结果表明,改进算法在准确率、召回率和平均精度上分别达到 83.2%、78.1% 和 82.1%,较基准模型 YOLOv11 提升 3.1%、4.6% 和 2.6%,且优于 Faster-RCNN、YOLOv8 等对比模型,此外,通过可视化分析证明改进后的算法漏检率降低,可为矿用钢丝绳安全隐患的实时监测提供有效的技术方案。

关键词: 钢丝绳;缺陷检测;C3k2_RFACConv;注意力机制;DySample

中图分类号: TP391.4;TN911 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Research on surface defect detection algorithm for steel wire ropes used in coal mines based on YOLOv11

Guo Xupeng Dong Lihong Qin Yi

(School of Artificial Intelligence and Computer Science, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: Addressing the issues of significant scale differences in small targets and strong interference from complex backgrounds in the detection of surface defects on coal mine steel wire ropes, a deep learning detection algorithm based on an improved YOLOv11 is proposed. Firstly, a receptive field attention feature extraction module, C3k2_RFACConv, is designed to enhance feature extraction capabilities under complex textures by dynamically adjusting convolution kernel weights. Secondly, a deformable large kernel attention mechanism, D-LKA, is introduced at the feature fusion layer, combining the advantages of large receptive fields and deformable convolutions to precisely focus on defect areas. Additionally, DySample upsampling optimization is adopted to suppress background noise interference and reduce the loss of small target features. Finally, an Inner-WIoU loss function is proposed to optimize bounding box regression and improve the localization accuracy of irregular defects. Experimental results show that the improved algorithm achieves an accuracy rate of 83.2%, a recall rate of 78.1%, and an average precision of 82.1%, which are 3.1%, 4.6% and 2.6% higher than those of the benchmark model YOLOv11, respectively. It also outperforms comparative models such as Faster-RCNN and YOLOv8. In addition, visual analysis proves that the improved algorithm has a reduced missed detection rate, providing an effective technical solution for real-time monitoring of potential safety hazards in mining steel wire ropes.

Keywords: wire rope; defect detection; C3k2_RFACConv; attention mechanism; DySample

0 引言

在煤矿生产中,钢丝绳作为重要的提升与运输工具,因

长期受到机械应力、摩擦以及腐蚀性物质的影响,容易出现断丝、磨损和腐蚀等表面缺陷^[1],因此,对钢丝绳进行定期且全面的表面缺陷检测对煤矿企业安全生产至关重要^[2]。

收稿日期:2025-06-07

* 基金项目:国家自然科学基金青年项目(62303375)资助

目前矿用钢丝绳缺陷检测方法大多为人工目视检测法和定期更换法^[3-4],检测耗时长,精确性和稳定性低且容易造成大量的钢材浪费。针对这一问题,国内外专家学者开展了广泛的探索,提出了电磁检测法^[5]、超声波检测法^[6]、X射线检测法^[7]、电涡流检测法^[8]等多种技术方案,虽然相较于人工具备较高的自动化程度和检测效率,但仍然存在无法有效判别损伤类型、易受检测环境干扰、泛化性差等问题。

近年来,随着人工智能技术的不断发展,基于深度学习的目标检测算法在工业缺陷检测领域取得了显著的研究成果^[9]。这些算法使用卷积神经网络(convolutional neural network, CNN)架构,自动学习钢丝绳表面缺陷的特征表示,从而实现断丝、磨损和腐蚀等缺陷的高效识别^[10]。相比传统方法,深度学习方法在检测精度和鲁棒性方面表现出明显优势,但在煤矿粉尘弥漫、光线昏暗等复杂生产环境中,钢丝绳表面缺陷易与杂乱的绳索纹理和煤尘等背景特征混淆,缺陷特征提取困难,缺陷目标难以识别。

目前的研究成果多以 YOLOv8、YOLOv5、YOLOv3 等模型作为基础进行改进,例如:郭鑫等^[11]提出一种改进的 YOLOv8 算法 YOLOv8-SLA,通过引入可分离核注意力模块(large separable kernel attention, LSKA)和辅助检测头,提高了模型对小目标缺陷的检测性能,但并没有对检测中可能存在的光照不足且分布不均匀,高浓度悬浮粉尘的复杂环境所带来的干扰进行研究;王红尧等^[12]在 YOLOv5 的基础上采用快速自适应加权中值滤波进行图像预处理,同时添加小目标检测头,提高了钢丝绳损伤识别准确率,但模型对不同损伤类型的泛化能力有待提高;Li 等^[13]提出了一种基于颜色分割和 Faster-RCNN 的钢丝绳缺陷检测算法,能够有效检测出钢丝绳的缺陷部位,但模型复杂度较高,参数数量和计算开销较大;方旭东等^[14]通过在卷积块注意力机制(convolutional block attention module, CBAM)的基础上引入残差将浅层特征和生成的深层特征相结合并添加随机池化的方式构建 CBAM-R 模块,提升了模型对钢丝绳表面断丝的特征提取能力,但其仅关注钢丝绳表面断丝检测,缺陷类别覆盖不足;Zhou 等^[15]将 YOLOv3 的骨干网络从 darknet53 更改为更轻量化的 Mobilenet,以减少计算复杂度和模型大小,提高了检测效率,但所采用的 YOLOv3 模型相对较老,对小目标缺陷检测不够敏感。

随着 YOLO 模型的不断优化,YOLOv11^[16]作为 Ultralytics 团队创建并维护的 YOLO 系列最新版本算法,它在 YOLOv8 的基础上进一步改进,YOLOv11 通过在骨干网络中引入 C3k2 模块与跨通道金字塔显著注意力模块(cross stage partial with pyramid squeeze attention, C2PSA),在保持高检测精度的同时进一步提升了推理速度,其高效的特征提取与快速响应能力使其在钢丝绳表面缺陷检测场景中具备优势。然而,煤矿钢丝绳表面缺陷检

测场景具有的困难特征包括:缺陷尺度差异较大、形状不规则、井下粉尘油污干扰严重,以及绳索纹理与缺陷对比度低。YOLOv11 的 C3k2 模块虽通过多分支结构增强梯度流,但仍以固定感受野卷积为主,难以自适应地捕捉极端尺度差异;C2PSA 的金字塔显著注意力在空间网格上均匀分配权重,对细长、弯曲或点状缺陷缺乏针对性聚焦,导致小目标漏检和边界框偏移。此外,其默认最近邻上采样在复杂背景下易将煤尘误判为缺陷,而 CIoU 损失对低对比度边缘回归不敏感,进一步放大了误检与漏检。因此,本文以 YOLOv11 为基线,围绕“动态感受野-可变形注意力-自适应上采样-加权 IoU 回归”4 条主线进行改进,以解决背景干扰、尺度与形状多变问题,实现煤矿钢丝绳断丝、磨损、腐蚀 3 类缺陷的鲁棒检测。

1 基于 YOLOv11 的改进算法

改进后的 YOLOv11 网络结构如图 1 所示。首先,使用感受野注意力卷积^[17](receptive-field attention convolution, RFACConv)替换 Bottleneck 中的第 2 个卷积构建 C3k2_RFACConv 模块来克服传统卷积核在处理不同区域图像时因参数共享所带来的问题,该模块通过结合空间注意力和感受野特征的处理来增强模型的特征提取及融合能力,从而提升模型对于复杂多变场景及模式的表达能力;其次,为实现对钢丝绳表面缺陷特征的精细化关注,在特征融合层中引入可变形大核注意力机制^[18](deformable large kernel attention, D-LKA),其结合了大卷积核的广阔感受野和可变形卷积的灵活性以适应不同形态和大小的缺陷目标,有效地处理复杂的视觉信息,进而提高模型在复杂背景中对缺陷目标的识别能力;再次,采用 DySample^[19]优化上采样方法,通过自适应聚焦关键区域以抑制背景纹理干扰,捕捉图像中的细微特征,减少特征信息的丢失;最后在此基础上设计了 Inner-WIoU 损失函数以改善预测边界框的回归损失,提升模型在复杂检测环境下的定位精度和泛化能力。

1.1 C3k2_RFACConv 特征提取

钢丝绳本身的结构和缺陷背景环境相近,缺陷特征与周围环境的对比度较低,难以被有效识别。例如,钢丝绳的纹理与断丝、磨损和腐蚀等缺陷特征可能具有相似的视觉外观,从而增加了检测的难度。此外,矿用钢丝绳在实际生产中可能受到光照变化、粉尘覆盖、油污污染以及机械变形等因素的影响,这些都会进一步干扰缺陷特征的提取。

在 YOLOv11 模型中,普通卷积操作由于参数共享的特性(即卷积核在处理不同区域的图像时共享同样的权重参数),无法有效区分重要和次要信息,导致特征提取的灵活性和针对性不足。此外,普通卷积在处理大尺寸卷积核时,难以解决参数共享带来的问题,限制了其对复杂场景的适应能力。对此,本文引入 RFACConv 感受野注意力卷积来解决参数共享的问题,帮助模型更好地聚焦于目标特征。感受野注意力卷积过程如图 2 所示。

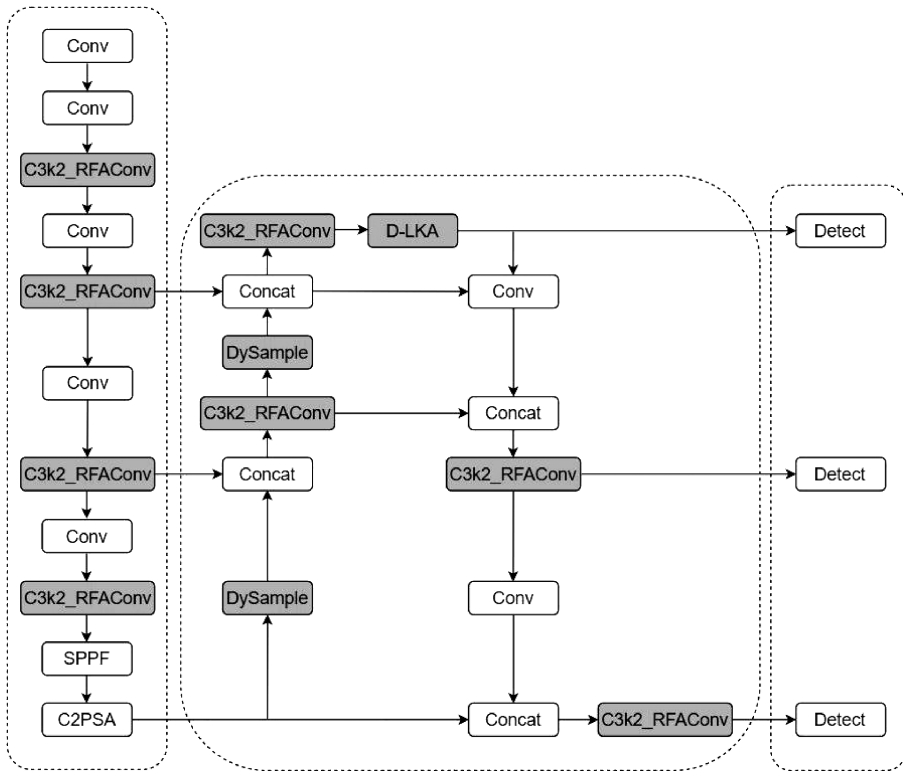


图1 改进YOLOv11网络结构

Fig. 1 Improved YOLOv11 network architecture

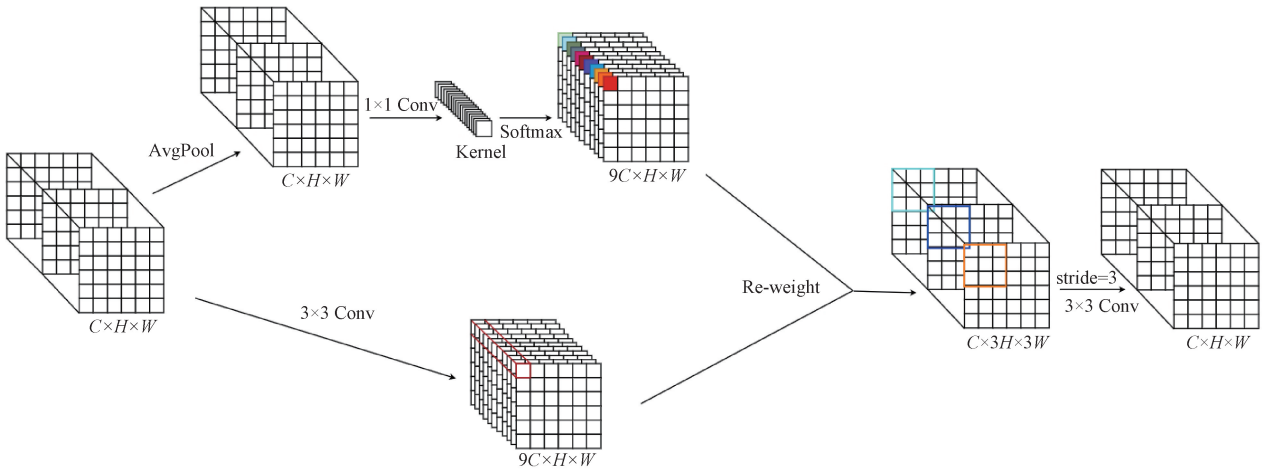


图2 RFACnv过程图

Fig. 2 RFACnv process diagram

首先,RFACnv通过组卷积快速提取输入特征图的感受野空间特征,生成不重叠的滑动窗口以避免特征重叠和共享问题,接着对这些原特征图进行AvgPool操作聚合每个感受野特征的全局信息,接着使用 1×1 组卷积进行信息交互,最后使用Softmax函数生成并归一化每个感受野区域的注意力权重,突出重要特征,然后将这些权重与感受野空间特征相乘,加权不同区域的特征以增强重要特征表示,最后整合加权后的特征得到最终卷积结果,从而

有效解决传统卷积中的参数共享问题。感受野注意力卷积的计算过程如式(1)所示。

$$F = \text{Softmax}(g^{1 \times 1}(\text{AvgPool}(X))) \times \text{ReLU}(\text{Norm}(g^{k \times k}(X))) = A_{rf} \times F_{rf} \quad (1)$$

其中, $g^{k \times k}$ 表示尺寸为 $k \times k$ 的分组卷积, k 代表卷积核的大小, Norm 代表归一化, X 表示输入特征图,输出特征 F 是通过将注意力图 A_{rf} 与变换的感受野空间特征 F_{rf} 相乘而获得的。

本文在 C3k2 中使用 RFACnv 替换 Bottleneck 中的第 2 个卷积,以降低普通卷积参数共享的特性所带来的局部图像特征提取不足的问题,同时有效捕捉和处理重要的感受野空间特征,更好地保留小目标缺陷的细节信息,其结构如图 3 所示,融入了感受野注意力卷积的 C3k2_RFACnv 模块通过利用感受野注意力机制来动态地调整卷积核的权重^[20],为每个区域的特征提取提供了定制化的关注度,从而提高模型在复杂缺陷背景下的特征提取能力。

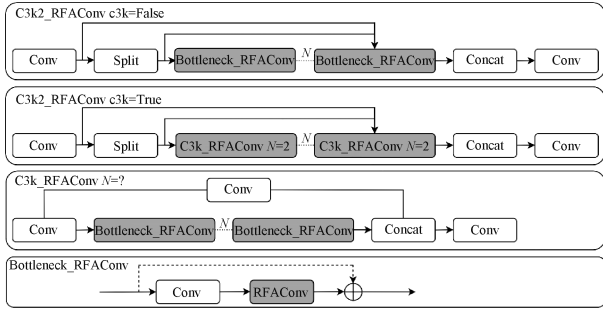


图 3 C3k2_RFACnv 结构

Fig. 3 C3k2_RFACnv structure

1.2 D-LKA 注意力聚焦

在煤矿用钢丝绳表面缺陷检测中,其表面的断丝、磨损和腐蚀等缺陷通常尺寸较小且形状不规则,同时这些缺陷在复杂的煤矿环境下,容易被背景噪声如煤尘、油污和杂乱的纹理等掩盖。在利用 YOLOv11 模型进行特征提取时,这些背景噪声会干扰缺陷特征的提取,导致目标特征信息丢失或被稀释,这不仅增加了检测难度,还使得模型在定位缺陷时不够精准。

注意力机制经常被应用于提升模型对目标区域的关注度。因此,为了增强模型对缺陷特征的关注度,提升检测的准确性和鲁棒性,本文在模型的颈部网络中引入 D-LKA 注意力机制模块。该模块通过使用大卷积核捕获图像中大量的上下文信息,模拟类似于自注意力机制的大感受野,同时避免了传统自注意力机制的计算负担。此外, D-LKA 还引入可变形卷积,通过额外的卷积层生成偏移场,动态地调整采样网格,以适应不同形状和大小的目标,增强模型的灵活性和适应性。大卷积核与可变形卷积的结合使用,进一步增加了模型对复杂图像模式的适应性。D-LKA 注意力结构如图 4 所示。

在二维网络架构中,编码器通过卷积初始层将输入图像尺寸减小到 $H/4 \times W/4 \times C$,并生成 4 层输出表示。经过 4 个 MaxViT 模块的特征提取后,每个模块后跟一个下采样层。进入解码器后,实现 4 个 DLKA 层,每个 DLKA 层包含 2 个 DLKA 模块,用于分辨率上采样和通道维度的降维。最后,通过线性层生成最终输出。二维 D-LKA 模块结构由 LayerNorm、D-LKA 和多层感知器(MLP)组成,通过引入残差连接,确保特征即使在较深的网络层中也能实现有效的特征传播。这种结构可以用数学公式表示为:

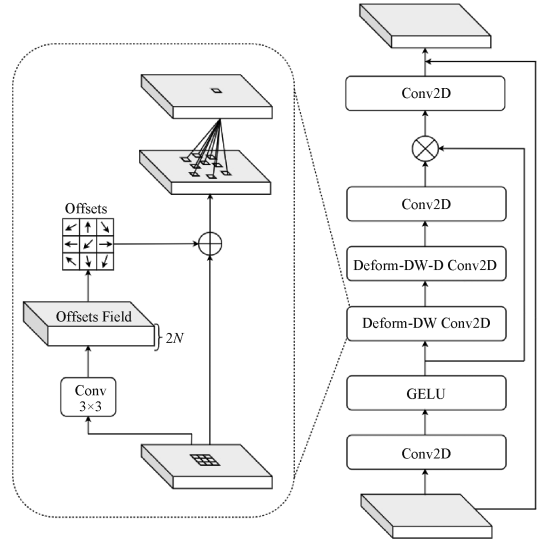


图 4 D-LKA 注意力结构

Fig. 4 D-LKA attention structure

$$x_1 = D-LKA-Attn(LN(x_{in})) + x_{in} \quad (2)$$

$$x_{out} = MLP(LN(x_1)) + x_1 \quad (3)$$

$$MLP = Conv_1(GeLU(Conv_d(Conv_1(x)))) \quad (4)$$

其中, x_{in} 为输入特征; LN 为层归一化; $D-LKA-Attn$ 为可变形 LKA 注意力; $Conv_d$ 为深度卷积; $Conv_1$ 为线性层; $GeLU$ 为激活函数。

D-LKA 注意力机制的引入增强模型对小尺寸和不规则缺陷特征的关注度,提升检测的准确性、鲁棒性和灵活性,适应煤矿复杂环境下的缺陷检测需求。

1.3 DySample 上采样优化

在煤矿用钢丝绳表面缺陷检测中,常用的最近邻插值和双线性插值上采样算子由于感受野有限,难以有效区分目标缺陷与背景特征。这导致在多尺度特征融合过程中,大量缺陷特征信息被丢失,模型无法准确识别和定位缺陷,尤其对于小目标缺陷,检测准确率显著下降。此外,传统上采样方法对噪声敏感,易将背景干扰误判为缺陷特征,进一步降低了检测性能。

因此,本文引入了动态上采样算子 DySample,通过点采样的方式重新定义上采样过程,不仅显著增强了模型对噪声的抗干扰性,还减少了参数数量,提升了计算资源的利用效率,优于传统的基于内核的动态上采样模块^[21]。此外,在采样过程中通过引入静态和动态偏移范围因子,使其能够精准控制偏移范围,避免采样点重叠,从而实现更准确的上采样操作。

DySample 的网络结构如图 5 所示。Dysample 主要包括动态上采样和采样点生成器模块。从输入特征(X)通过采样点生成器创建采样集(S),然后利用网络样本(grid_sample)函数对输入特征进行重新采样,得到上采样特征图(X')。这一上采样过程如式(5)所示。

$$X' = grid_sample(X, S) \quad (5)$$




图5 DySample网络结构

Fig. 5 DySample network structure

在采样点生成器中,采样集(S)由原始采样网络(G)和生成的偏移量(O)组成,运算过程如式(6)所示。

$$S = G + O \quad (6)$$

偏移量的生成采用“线性+像素洗牌”的方法,其中偏移量的范围由静态和动态因素确定。具体来说,以静态因子采样方法为例,给定大小为 $C \times H \times W$ 的特征图和一个上采样因子 s ,特征图首先通过输入通道为 C 和输出通道为 $2s^2$ 的线性层,生成大小为 $2s^2 \times h \times w$ 的偏移量 O ,然后使用像素洗牌技术将其重塑为 $2 \times sH \times sW$,其中 2 表示 x 和 y 坐标。最后可以生成尺寸大小为 $c \times sH \times sW$ 的上采样特征图。

静态范围操作过程如式(7)所示。

$$O = 0.25(\text{linear}(x)) \quad (7)$$

动态范围操作过程如式(8)所示。

$$O = 0.5\text{sigmoid}(\text{linear}_1(X)) \times \text{linear}_2(X) \quad (8)$$

其中, X 为输入特征, X' 为上采样特征, S 为采样集, G 为原始采样网络。

图5(a)由采样点生成器生成采样集 S ,网络采样对输入特征进行重新采样。图5(b)部分则展示了DySample中的采样点生成器,其中采样集由生成的偏移量与原始网络位置相加得到。图5(b)上半部分表示静态范围因子,下半部分表示动态范围因子,范围因子的生成共同实现了自适应上采样的目标。

DySample通过重塑上采样流程,有效减少了多尺度特征融合过程中的特征信息丢失,精准区分目标缺陷与复杂背景特征,提高了检测准确率,为煤矿钢丝绳表面缺陷检测提供了更高效的解决方案。

1.4 损失函数

YOLOv11原模型采用的完全交并比损失函数(complete intersection over union, CIoU)难以准确衡量预测框与真实框的相似度,对小目标以及不规则缺陷的检测不够敏感,容易漏检。因此本文算法引入内部交并比损失函数^[22](inner intersection over union, Inner-IoU)进行改进,Inner-IoU损失函数只关注预测边界框与真实边界框之间的重叠区域,更注重模型对目标内部区域的定位能力,帮助模型更准确地定位目标。

Inner-IoU的工作示意图如图6所示,在Inner-IoU方法中,通过引入尺度因子 $ratio$,根据真实边界框和预测边界框的中心点坐标、宽高以及尺度因子 $ratio$ 来确定辅助边界框的位置和大小,计算预测辅助边界框与真实辅助边界框之间的交集和并集,得到Inner-IoU值。通过改变尺度因子 $ratio$ 的值,可以控制辅助边界框相对于真实边界框或预测边界框的大小,当 $ratio < 1$ 时,辅助边界框会比实际边界框小,有助于高IoU样本的回归;当 $ratio > 1$ 时,辅助边界框会比实际边界框大,有助于低IoU样本的回归。具体定义如下:

$$b_l^{gt} = x_c^{gt} - \frac{w^{gt} \times ratio}{2}, b_r^{gt} = x_c^{gt} + \frac{w^{gt} \times ratio}{2} \quad (9)$$

$$b_t^{gt} = y_c^{gt} - \frac{h^{gt} \times ratio}{2}, b_b^{gt} = y_c^{gt} + \frac{h^{gt} \times ratio}{2} \quad (10)$$

$$b_l = x_c - \frac{w \times ratio}{2}, b_r = x_c + \frac{w \times ratio}{2} \quad (11)$$

$$b_t = y_c - \frac{h \times ratio}{2}, b_b = y_c + \frac{h \times ratio}{2} \quad (12)$$

$$inter = (\min(b_l^{gt}, b_r) - \max(b_l, b_t)) \times (\min(b_b^{gt}, b_b) - \max(b_t^{gt}, b_t)) \quad (13)$$

$$union = (w^{gt} \times h^{gt})(ratio)^2 + (w \times h)(ratio)^2 - inter \quad (14)$$

$$IoU^{inner} = \frac{inter}{union} \quad (15)$$

其中, $ratio$ 为尺度因子, $inter$ 为真实框与预测框的交集, $union$ 为真实框与预测框的并集。

Inner-IoU在一定程度上改善了模型对缺陷的检测效果,但是在实验过程中出现模型对新场景数据适应性差,在验证集上泛化能力不足,导致损失收敛缓慢的问题,所以选择在Inner-IoU的基础上加入损失函数加权交并比^[23](wise intersection over union, WIoU)损失函数来提升模型的泛化能力和适应性。WIoU在CIoU的基础上引入了动态聚焦机制的IoU变体来改善边界框回归损失。其定义如下:

$$L_{WIoU} = R_{WIoU} L_{IoU} \quad (16)$$

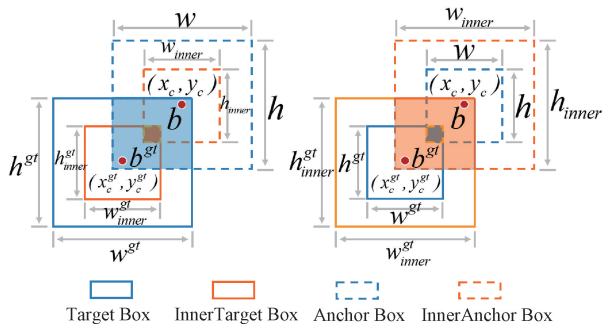


图 6 Inner-IoU 示意图

Fig. 6 Schematic diagram of Inner-IoU

$$R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)}\right) \quad (17)$$

其中, x, y 表示预测框的中心点坐标, x_{gt}, y_{gt} 真实框的中心点坐标, W_g, H_g 表示最小外接矩阵的宽和高。

最后根据 Inner-IoU 损失的设计思想将其集成到 WIoU 损失函数中, 获得 Inner-WIoU 损失函数, 其定义为:

$$L_{inner-WIoU} = L_{WIoU} + IoU - IoU^{inner} \quad (18)$$

设计的 Inner-WIoU 损失函数整合了 Inner-IoU 与 WIoU 的优势, 增强了模型对不同场景数据的泛化能力, 验证了其在提高检测精度和模型可靠性方面的有效性。

2 实验结果与分析

2.1 数据集

煤矿用钢丝绳表面缺陷中, 断丝主要由制造缺陷或机械过载引发, 形成斜茬状断口威胁设备安全; 表面磨损由外部摩擦导致绳径变细与抗拉强度下降; 腐蚀则因井下潮湿环境引发锈蚀, 削弱机械强度并加剧断丝与磨损。

本文自建数据集来源于煤矿生产环境中的提升和运输、悬挂装置、挂车和索道运输等钢丝绳应用场景, 如图 7 所示。




图 7 钢丝绳应用场景

Fig. 7 Application scenarios of steel wire rope

在上面这些生产场景中, 钢丝绳表面缺陷主要有以下 3 种类型, 如图 8 所示。

为了提升模型的鲁棒性和泛化能力, 通过对每张原始数据进行以下 7 种变换中的随机两种的方式增强数据集: 加噪声、调整亮度、cutout、随机翻转、裁剪、平移和镜像, 整理后共有 4 627 张图像, 覆盖了断丝、磨损和腐蚀 3 种缺陷类型, 数据集增强前后每种类别图像的数量对比如表 1 所示。



(a) 断丝 (a) Broken wire (b) 磨损 (b) Wear and tear (c) 腐蚀 (c) Corrosion

图 8 数据集中 3 种缺陷类型

Fig. 8 Three types of defects in the dataset

表 1 数据增强前后图像数量

Table 1 Number of images before and after data augmentation

缺陷类型	数据增强前/张	数据增强后/张
断丝	984	2 242
磨损	395	1 025
腐蚀	637	1 360
总计	2 016	4 627

2.2 实验配置

本文实验具体参数配置如表 2 所示, 算法的训练迭代次数设置为 200, 批次设置为 16, 将输入图像统一变换为 640×640 , 采用随机梯度下降策略 (SGD) 优化器进行算法训练, 初始学习率为 0.01, 最终学习率为 0.000 1, 权重衰减 0.000 5, 动量参数为 0.937。

表 2 实验环境配置

Table 2 Experimental environment configuration

实验环境	参数配置
CPU	Intel(R)Xeon(R)Platinum8362
GPU	RTX3090(24 GB)
操作系统	Windows 11 64 位
Python	3.8(ubuntu18.04)
Pytorch	1.8.1
Cuda	11.1

2.3 评价指标

为了全面客观准确地评价所改进的 YOLOv11 算法的性能, 本文使用准确率 P、召回率 R、所有类别的平均精度值 (mean average precision, mAP)、模型参数量 Params、模型计算量 GFLOPs 几项指标来衡量。其中, Params 代表模型需要学习的参数数量, 与模型的复杂度相关。GFLOPs 代表每秒可以执行的十亿次浮点运算, GFLOPs 的值越大表示需要更多的计算资源来执行检测任务。部分公式如式 (19)~(22) 所示。

$$P = \frac{TP}{TP + FP} \quad (19)$$

$$R = \frac{TP}{TP + FN} \quad (20)$$

$$AP = \int_0^1 P(R) dR \quad (21)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (22)$$

其中, TP 表示模型在含有缺陷的图像中正确检测出缺陷; FP 表示模型在不含缺陷的图像中错误地将其他目标检测为缺陷; FN 表示模型在含有缺陷的图像中未能检测出缺陷。

2.4 损失函数对比分析

为了进一步验证 Inner-WIoU 损失函数的有效性,在相同的实验条件下,将 CIoU、GIoU、SIoU、EIoU、WIoU、Inner-IoU 与 Inner-WIoU 进行对比实验,实验结果如表 3 所示。

表 3 损失函数对比结果

损失函数	P	R	mAP@0.5
CIoU	80.1	73.5	79.5
GIoU	79.6	73.9	79.4
SIoU	79.3	77.7	78.6
EIoU	78.8	73.0	78.1
WIoU	79.9	74.9	79.7
Inner-IoU	80.7	74.5	79.8
Inner-WIoU	81.4	76.3	80.0

通过分析损失函数对比实验可知,GIoU、SIoU 和 EIoU 对比原 YOLOv11 的 CIoU 精确度 P 和平均精度 mAP 都有不同程度的下降,WIoU 虽然在精确度 P 上有较小程度的下降,但是 $mAP@0.5$ 提高了 0.2%,Inner-IoU 对比 CIoU 在各个性能指标上都有一定提升,但是在实验过程中出现模型对新场景数据适应性差,在验证集上泛化能力不足,导致损失收敛缓慢的问题,所以选择在 Inner-IoU 的基础上加入 WIoU 损失函数,与基础损失函数 CIoU 相比,Inner-WIoU 在准确率、召回率和平均精度分别提升 1.3%、2.8% 和 0.5%,有效提升了模型的检测性能。

2.5 消融实验

为了验证各个改进策略的有效性,本文在同一设备相同参数下设计并完成 9 组消融实验。

在煤矿钢丝绳缺陷检测任务中,小目标、复杂背景干扰和不规则形状对特征表达要求极高。因此本文以提高检测精度为核心目标,保证检测鲁棒性,所以改进相比基准 YOLOv11 引入了额外计算单元,参数量与 GFLOPs 的同步增加是“以精度为导向”的代价。得到的实验结果如表 4 所示,实验结果验证了该代价带来的 3.1% 准确率、4.6% 召回率和 2.6% 平均精度的提升具有工程价值。

表 4 中,实验 1 为基础 YOLOv11 模型的实验结果,表中“✓”标记代表在对应改进点基础上进行的实验。实验 2 在 YOLOv11 网络中融入 D-LKA 注意力机制,D-LKA 通过将大卷积核与可变形卷积相结合,增强了模型对复杂图

表 4 消融实验结果

Table 4 Results of ablation experiment

实验	YOLOv11	D-LKA	C3k2_RFACConv	DySample	Inner-WIoU	P/%	R/%	mAP@0.5/%	Params/M	GFLOPs
1	✓					80.1	73.5	79.5	2.58	6.3
2	✓	✓				82.4	75.8	80.4	2.98	11.4
3	✓		✓			81.1	74.5	80.9	2.64	6.6
4	✓			✓		81.9	73.9	80.0	2.59	6.3
5	✓				✓	81.4	76.3	80.0	2.58	6.3
6	✓	✓	✓			83.1	74.3	80.4	3.04	11.8
7	✓	✓		✓		82.5	75.1	81.4	3.00	11.6
8	✓	✓	✓	✓		82.7	76.2	81.6	3.05	11.8
9	✓	✓	✓	✓	✓	83.2	78.1	82.1	3.05	11.8

像中缺陷的特征表达能力,模型的准确率、召回率和平均精度分别提升 2.3%、2.3%、0.9%,但由于 D-LKA 模块结构复杂,导致参数数量和 GFLOPs 略有增加。实验 3 在加入 C3k2_RFACConv 模块后,在计算量略微增加的情况下,准确率提高了 1%,平均精度提高了 1.4%,表明 C3k2_RFACConv 通过为重要特征赋予更高的权重有效解决了参数共享的问题,提升了模型在复杂背景下对小目标缺陷的识别能力。实验 4 中使用 DySample 替代 UpSample 模块后,在几乎不增加模型计算开销的情况下,与原模型相比,

准确率和平均精度分别提升 1.8% 和 0.5%,主要由于缺陷在图像中的像素占比通常较小,容易导致识别任务中特征学习困难以及特征图像细粒度丢失等问题,而 DySample 上采样方法能够有效避免这一问题。实验 5 替换 Inner-WIoU 损失函数后准确率、召回率和平均精度分别提升 1.3%、2.8% 和 0.5%,表明 Inner-WIoU 损失函数增强了边界框回归能力,改善了模型对缺陷目标的误检、漏检情况,提高了模型整体的检测精度。实验 6~9 在添加 D-LKA 注意力机制的基础上依次增加 C3k2_RFACConv、

DySample、Inner-WIoU,最终,将上述 4 种改进措施同时应用于 YOLOv11 模型后,与基线网络相比,模型准确率提升 3.1%,召回率提升 4.6%,平均精度提升 2.6%。尽管模型的参数量增加了 0.47 M,但改进措施的协同作用显著增强了模型检测钢丝绳表面缺陷的能力,使模型性能得到显著提升。

图 9 可视化展示了 9 组消融实验对应的 mAP@0.5 训练曲线局部放大图。为突出不同模块组合间的差异,纵坐标被限定在 0.65~0.85 区间,横坐标覆盖 0~200 epoch。由图 9 可知:所有曲线均在训练初期迅速爬升,50~100 epoch 增速明显放缓,约在 100 epoch 后进入平稳收敛阶段;随着改进模块的逐次叠加,曲线上升速率依次加快,收敛高度亦逐级抬升。至训练末期,实验 9(集成全部 4 项改进)的曲线不仅最先达到高位平台,且全程波动较小,最终稳态 mAP@0.5 明显优于其他组合,直观证明了各模块协同作用对检测性能的稳定提升。

2.6 对比实验

目前缺陷检测方向的研究主要集中在 YOLOv5、YOLOv7、YOLOv7-tiny、YOLOv8、YOLOv9、YOLOv10、

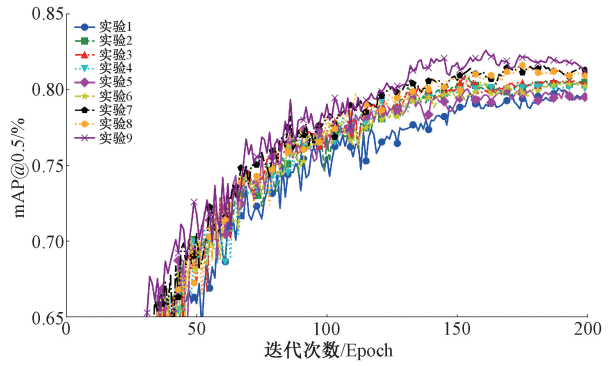


图 9 消融实验训练过程 mAP 变化曲线

Fig. 9 Change curve of mAP during training of ablation experiment

YOLOv11 基础模型上的改进,为进一步验证改进算法在钢丝绳表面缺陷检测任务上的性能,本文选取基于上述模型的改进算法以及常用的二阶段目标检测网络 Faster-RCNN 作为对比实验。为了保证实验的公平性,所有实验均在相同的实验环境下进行,并使用相同的数据集。实验结果如表 5 所示。

表 5 不同模型对比实验

Table 5 Comparison experiments of different models

模型	P/%	R/%	mAP@0.5/%	Params/M	GFLOPs
Faster-RCNN	79.5	75.1	80.3	42.20	137.4
YOLOv5	79.9	74.6	80.3	7.10	15.8
YOLOv7-tiny	76.0	68.4	72.4	6.02	13.2
YOLOv7	75.2	66.7	71.5	37.20	105.1
YOLOv8	80.1	73.5	78.4	3.00	8.1
YOLOv9	82.7	75.1	81.1	7.20	27.4
YOLOv10	77.7	74.0	78.3	2.69	8.2
YOLOv11	80.1	73.5	79.5	2.58	6.3
YOLO_BF ^[24]	77.0	77.4	77.6	2.62	8.0
YOLOv5_TPH ^[12]	80.4	74.2	80.4	18.9	187.3
YOLOv8-SLA ^[11]	81.7	75.9	80.7	2.65	7.4
Ours	83.2	76.6	82.1	3.05	11.8

从不同模型的对比实验可知,改进的 YOLOv11 模型的准确率、召回率、平均精度均值分别为 83.2%、76.6%、82.1%,对比其他检测模型,改进的 YOLOv11 模型在平均精度均值上相比 Faster-RCNN、YOLOv5、YOLOv7-tiny、YOLOv7、YOLOv8、YOLOv9、YOLOv10、YOLOv11 以及 YOLO_BF、YOLOv5_TPH、YOLOv8-SLA 分别提高了 1.8%、1.8%、9.7%、10.6%、3.7%、1%、3.8%、2.6%、4.5%、1.7%、1.4%,表明了改进的 YOLOv11 算法在矿用钢丝绳表面缺陷检测中具有更高的精确性,尤其是在复杂场景下误检率更低、漏检更少。由实验结果可知,YOLOv8-SLA 在实现轻量化的同时保持了较高的检测精

度,但是距本文性能数据仍有较大差距;YOLO_BF 在轻量化方面取得较大优势,但是模型精度较低;YOLOv5_TPH 是在 YOLOv5 的基础上进行的改进,虽然在模型精度方面相较于原 YOLOv5 取得一定的提升,但是由于在模型中引入了 Transformer 结构,导致模型的复杂度较高;虽然 YOLOv9 的检测精度高于原 YOLOv11 的检测精度,但是其参数量和计算量是原 YOLOv11 的两倍之多;尽管改进算法的参数量和计算量略高于部分其他算法,但相较于 YOLOv7 等仍保持了极高的计算效率,体现了改进算法高效的训练和推理能力。

由图 10 可知,改进 YOLOv11 算法在识别钢丝绳表面

缺陷的过程中表现出较稳定的识别率,并更快地趋近于拟合状态。相比之下,YOLOv7、YOLOv7-tiny 在识别的过程中出现平均精度均值较低以及曲线波动较大的情况,说明他们在缺陷识别任务中不够稳定可靠。

综上,改进的YOLOv11算法在保证适当参数量和计算量的同时,有效提升了模型特征学习能力与检测鲁棒性,在复杂环境的钢丝绳表面缺陷检测任务中性能更符合应用要求。

2.7 缺陷检测效果可视化分析

为直观准确地评估本文改进算法在钢丝绳表面缺陷检测方面的性能,从钢丝绳缺陷数据集的测试集中挑选了4张钢丝绳缺陷图片如图11所示,本文改进后算法以及表5中对比检测算法的可视化缺陷检测效果如图12~23所示,缺陷的检测结果如表6所示。

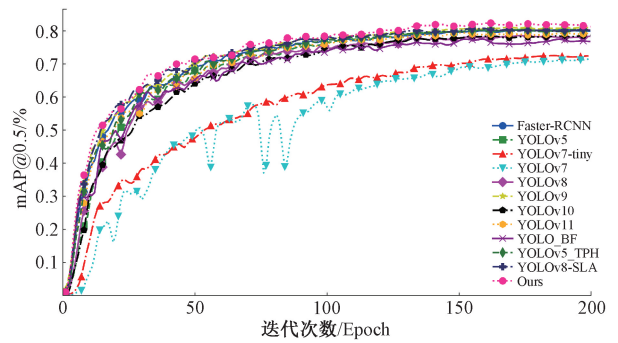


图10 对比实验训练过程 mAP 变化曲线
Fig. 10 Comparison of mAP change curves during experimental training

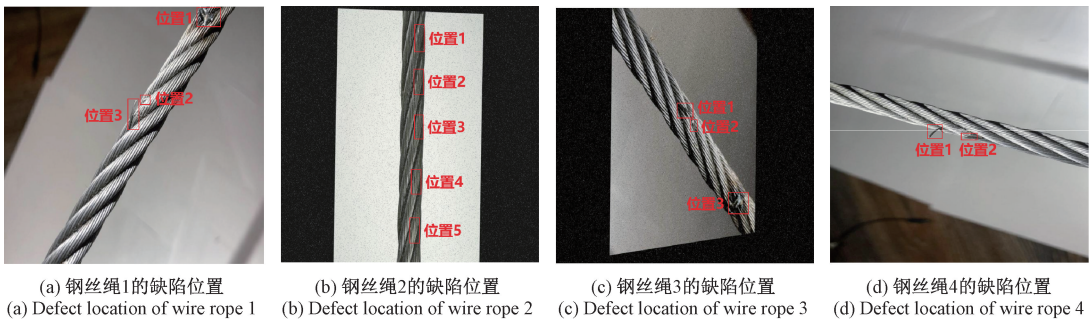


图11 钢丝绳缺陷图

Fig. 11 Defect diagram of steel wire rope

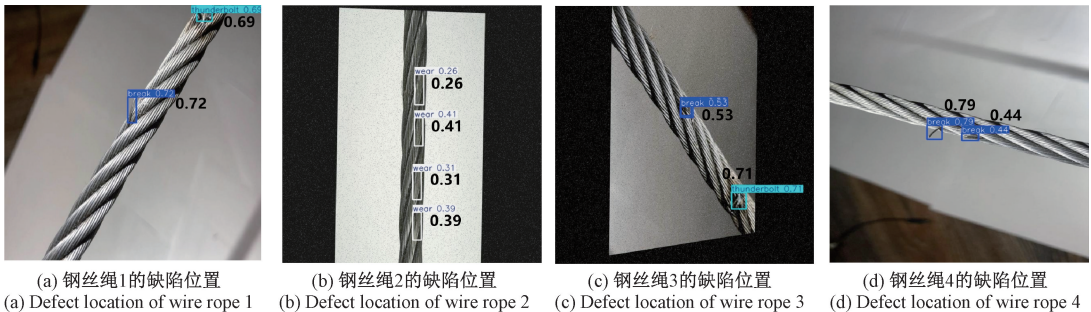


图12 Faster-RCNN 缺陷检测效果

Fig. 12 Faster-RCNN defect detection performance

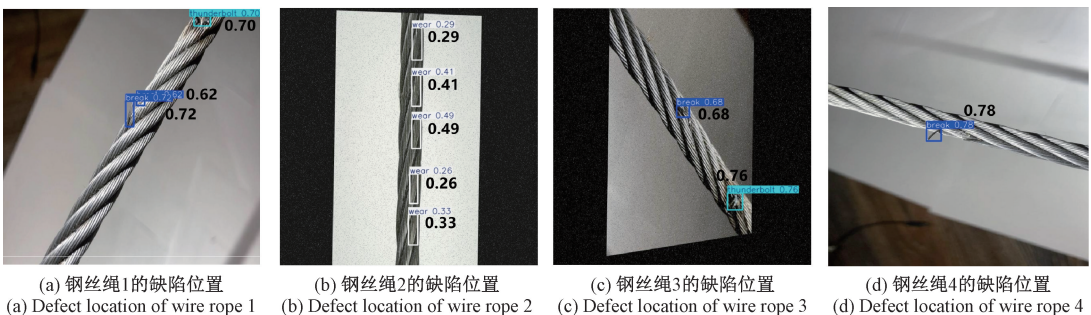


图13 YOLOv5 缺陷检测效果

Fig. 13 YOLOv5 defect detection performance

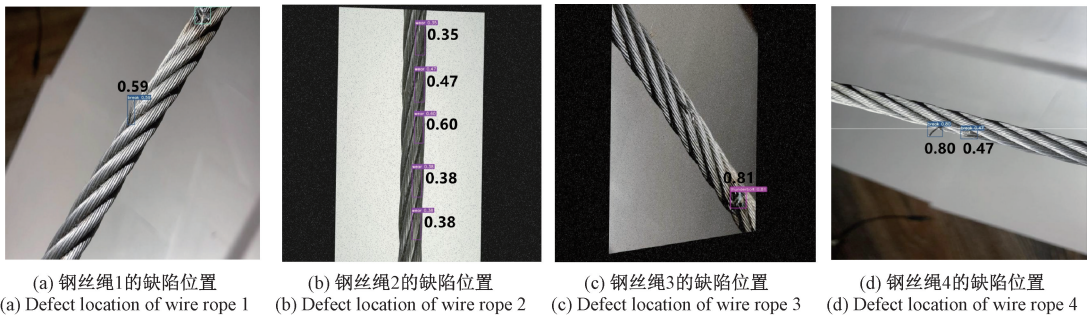


图 14 YOLOv7-tiny 缺陷检测效果

Fig. 14 YOLOv7-tiny defect detection performance

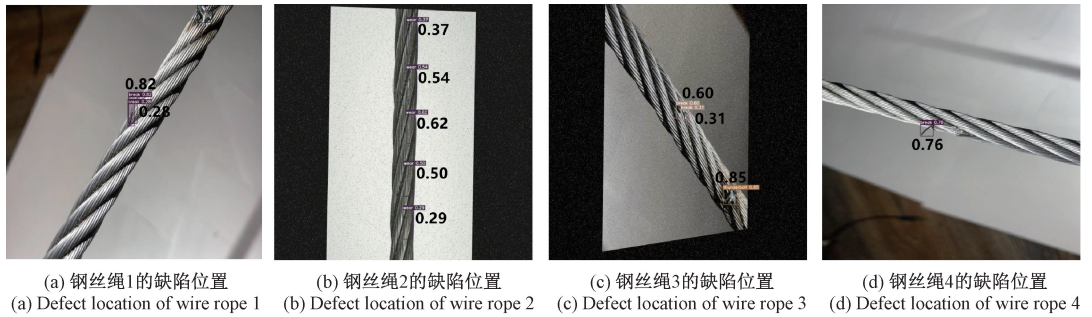


图 15 YOLOv7 缺陷检测效果

Fig. 15 YOLOv7 defect detection performance

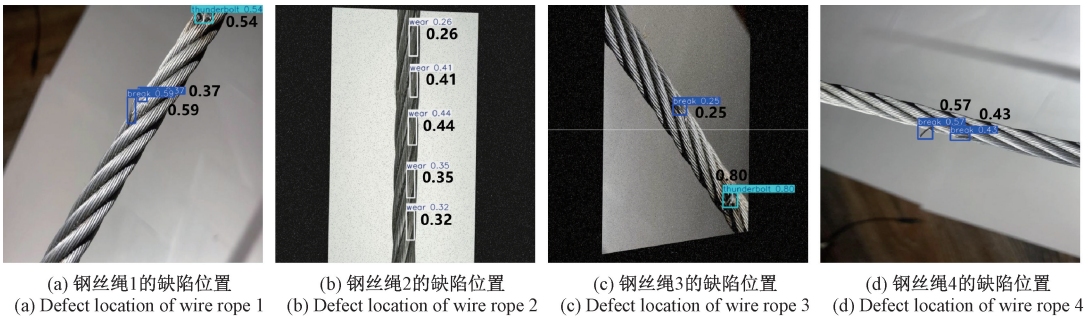


图 16 YOLOv8 缺陷检测效果

Fig. 16 YOLOv8 defect detection performance

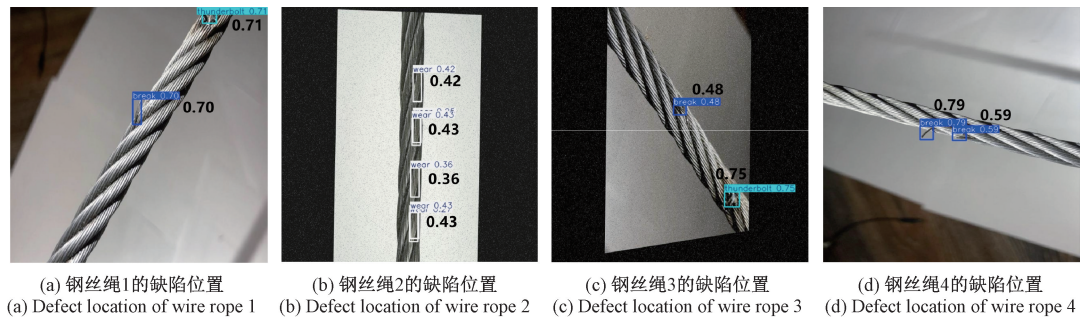


图 17 YOLOv9 缺陷检测效果

Fig. 17 YOLOv9 defect detection performance

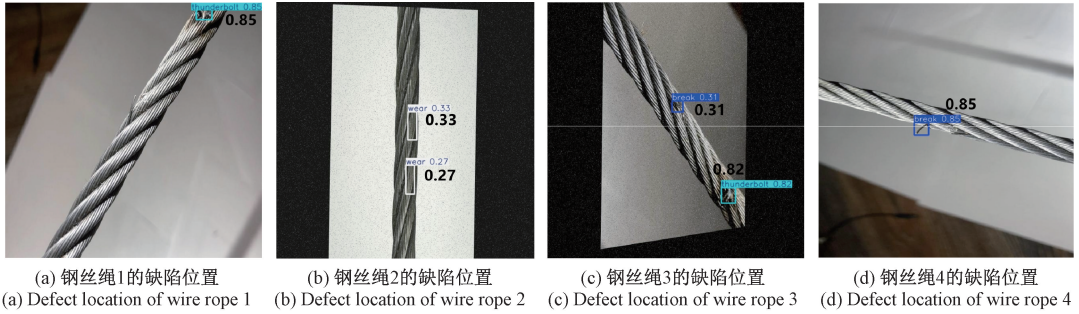


图 18 YOLOv10 缺陷检测效果

Fig. 18 YOLOv10 defect detection performance

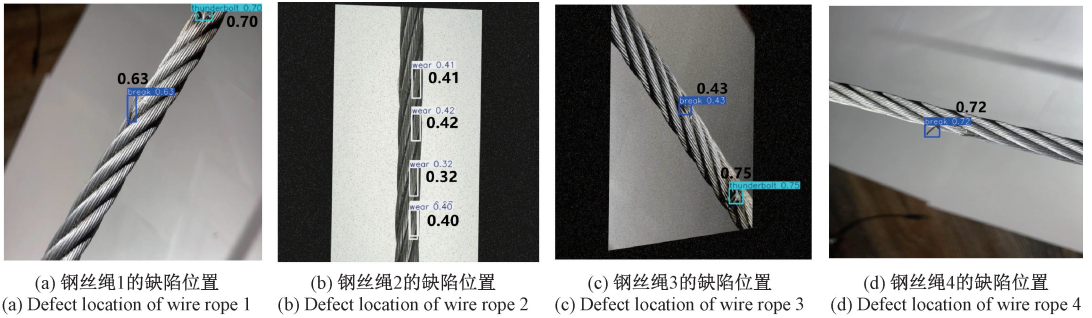


图 19 YOLOv11 缺陷检测效果

Fig. 19 YOLOv11 defect detection performance

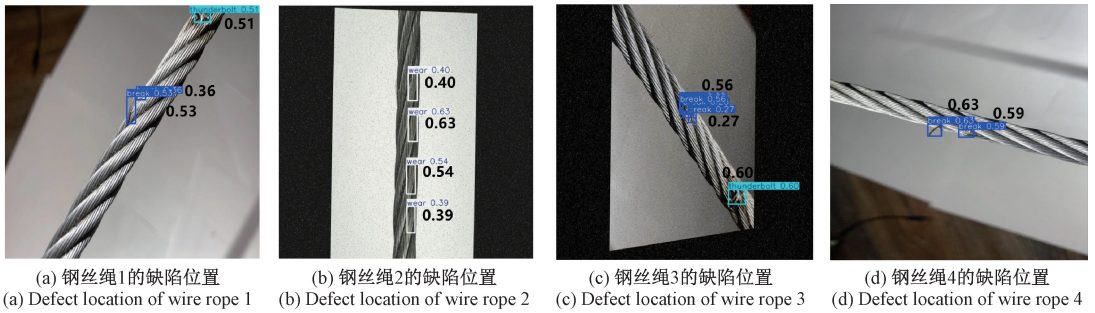


图 20 YOLO_BF 缺陷检测效果

Fig. 20 YOLO_BF defect detection performance

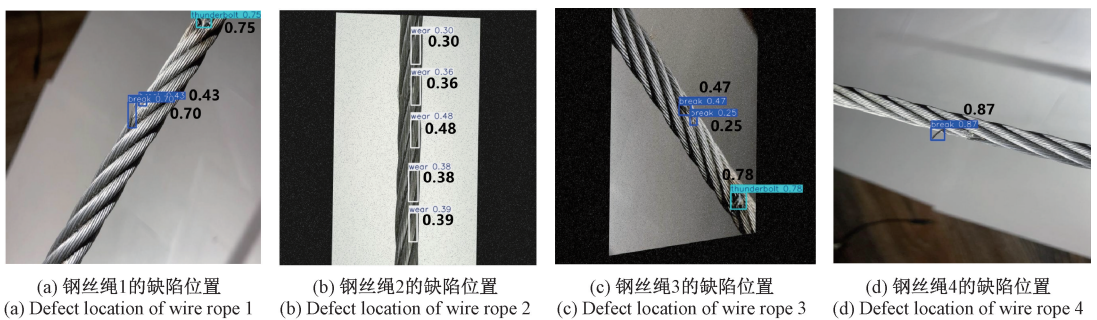


图 21 YOLOv5_TPH 缺陷检测效果

Fig. 21 YOLOv5_TPH defect detection performance

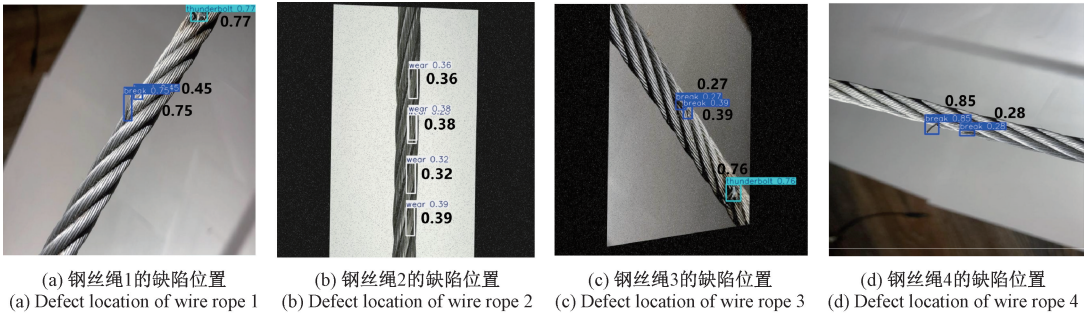


图 22 YOLOv8_SLA 缺陷检测效果

Fig. 22 YOLOv8_SLA defect detection performance

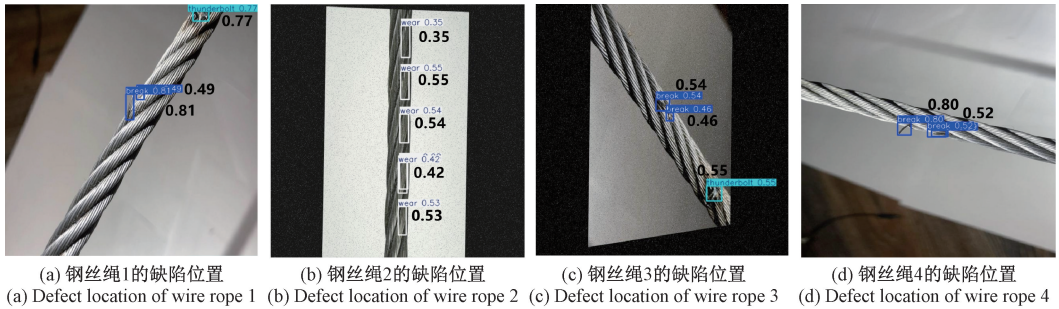


图 23 本文缺陷检测效果

Fig. 23 Ours defect detection performance

表 6 缺陷检测结果

Table 6 Defect detection results

模型	原图(a)			原图(b)					原图(c)			原图(d)	
	位置 1	位置 2	位置 3	位置 1	位置 2	位置 3	位置 4	位置 5	位置 1	位置 2	位置 3	位置 1	位置 2
Faster-RCNN	✓		✓		✓	✓	✓	✓		✓	✓	✓	✓
YOLOv5	✓	✓	✓	✓	✓	✓	✓	✓	✓		✓	✓	
YOLOv7-tiny	✓		✓	✓	✓	✓	✓	✓			✓	✓	✓
YOLOv7	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	
YOLOv8	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
YOLOv9	✓		✓		✓	✓	✓	✓	✓	✓	✓	✓	✓
YOLOv10	✓					✓	✓	✓	✓	✓	✓	✓	
YOLOv11	✓		✓		✓	✓	✓	✓	✓	✓	✓	✓	
YOLO_BF	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓	✓	✓
YOLOv5_TPH	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓	
YOLOv8-SLA	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓	✓	✓
本文	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

结合图 11~23 和表 6 可以很直观地看出,改进后的 YOLOv11 算法可以更准确地识别定位到缺陷位置,并未出现对比算法在检测中所存在的漏检问题,说明改进后的 YOLOv11 算法能够克服一些复杂检测场景的干扰,并对小目标缺陷保持较高的准确率,同时改进算法对缺陷细节特征具有更强的感知和提取能力。

3 结 论

针对煤矿用钢丝绳表面断丝、磨损、腐蚀等缺陷检测中存在的检测环境复杂、缺陷形态尺度各异、检测精度低等问题,本文提出一种基于 YOLOv11 的深度学习检测算法,通过引入感受野注意力卷积 RFACConv,构建 C3k2_

RFACnv 模块来加强模型对于复杂检测场景的适应能力,捕捉更多的小目标特征信息。在颈部网络中引入 D-LKA 注意力机制以增强模型对不同尺度缺陷特征的提取能力,提升检测精度。通过采用 DySample 上采样算子改进最近邻插值方法,自适应地增强模型多尺度特征融合效果,减少特征信息损失,更好地保留图像细节信息。最后,使用 Inner-WIoU 损失函数改善边界框回归损失,减少误检和漏检情况,提升对小目标和形状不规则缺陷的检测性能。

实验结果表明,本文提出基于 YOLOv11 的改进算法在保证检测效率的情况下,钢丝绳表面缺陷的检测精度提高,实现了更为均衡的检测性能。与原始网络相比,改进后的算法在准确率、召回率和 mAP 方面分别提升了 3.1%、4.6% 和 2.6%,具有良好的检测效果。

在后续的研究中,一方面将扩大数据集规模,增加缺陷类别,提升模型的泛化能力和鲁棒性。另一方面在继续提升模型检测性能的同时降低模型复杂度,并进一步探索算法在边缘检测设备的部署方案,构建一个实时、高效、可靠的钢丝绳表面缺陷检测系统。

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.
ZHAO W, XUE T, FAN CH H, et al. Research on online detection method for damage of wire rope of mine hoist [J]. Mining & Processing Equipment, 2022,50(6):22-26.
- [2] 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 SH 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.
- [3] LI X H, HE L, CUI T S, et al. Research on optimisation and extension of comprehensive detection method of steel wire rope for mine[J]. Science and Technology Innovation Guide,2018,15(2):36-38.
- [4] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报,2022,43(1):198-219.
ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument,2022,43(1):198-219.
- [5] ZHANG J, TAN X, ZHENG P. Non-destructive detection of wire rope discontinuities from residual magnetic field images using the Hilbert-Huang transform and compressed sensing[J]. Sensors, 2017, 17(3):608.
- [6] SONG W, XU C, PAN Q, et al. Nondestructive testing and characterization of residual stress field using an ultrasonic method[J]. Chinese Journal of Mechanical Engineering,2016,29(2):365-371.
- [7] CHAKHLOV S, ANPILOGOV P, BATRANIN A, et al. Generation and analysis of wire rope digital radiographic images [C]. IOP Conference Series: Materials Science and Engineering, IOP Publishing, 2016, 132(1): 012008.
- [8] 于小杰,李旭东,解社娟,等. 钢丝绳断丝缺陷涡流检测方法[J]. 中国机械工程,2019,30(22):2757-2763.
YU X J, LI X D, XIE SH J, et al. ECT method for wire breakage defects in wire ropes [J]. China Mechanical Engineering,2019,30(22):2757-2763.
- [9] 李键,李华,胡翔坤,等. 基于深度学习的表面缺陷检测技术研究进展[J]. 计算机集成制造系统,2024,30(3):774-790.
LI J, LI H, HU X K, et al. Research progress of surface defect detection technology based on deep learning [J]. Computer Integrated Manufacturing Systems,2024,30(3):774-790.
- [10] 刘晓磊,吴国群,阚哲. 基于深度学习的煤矿钢丝绳缺损检测方法研究[J]. 煤炭工程,2023,55(11):148-153.
LIU X L, WU G Q, KAN ZH. Research on defect detection method of coal mine wire rope based on deep learning[J]. Coal Engineering,2023,55(11):148-153.
- [11] 郭鑫,马行,穆春阳,等. 基于YOLOv8-SLA轻量化钢丝绳缺陷检测方法[J]. 组合机床与自动化加工技术,2025(3):140-144.
GUO X, MA X, MU CH Y, et al. Defect detection of lightweight steel rope based on YOLOv8-SLA model[J]. Modular Machine Tool & Automatic Manufacturing Technique,2025(3):140-144.
- [12] 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.
WANG H Y, HAN SH, LI Q Y. Experimental research on image recognition of wire rope damage based on improved YOLOv5 [J]. Computer Engineering and Applications,2023,59(17):99-106.
- [13] LI W, DONG T, SHI H, et al. Defect detection algorithm of wire rope based on color segmentation and faster RCNN[C]. 2021 International Conference on Control, Automation and Information Sciences (ICCAIS), 2021:656-661.
- [14] 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 ZH, YANG F ZH, et al. Research on broken wire detection algorithm of lightweight mine wire rope based on attention mechanism[J]. China Coal, 2024, 50(8):152-164.
- [15] ZHOU P, ZHOU G, WANG S, et al. Visual sensing inspection for the surface damage of steel wire ropes with object detection method [J]. IEEE Sensors Journal, 2022, 22(23):22985-22993.
- [16] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements[J]. ArXiv preprint arXiv:2410.17725, 2024.
- [17] ZHANG X, LIU C, YANG D, et al. RFACConv: Innovating spatial attention and standard convolutional operation [J]. ArXiv preprint arXiv: 2304.03198, 2023.
- [18] AZAD R, NIGGEMEIER L, et al. Beyond self-attention: Deformable large kernel attention for medical image segmentation[C]. IEEE/CVF Winter Conference on Applications of Computer Vision, 2024: 1287-1297.
- [19] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]. IEEE/CVF International Conference on Computer Vision, 2023:6027-6037.
- [20] 沈冰星, 黄洪琼. 基于 ESE-YOLO 的钢带表面缺陷检测研究[J]. 电子测量与仪器学报, 2025, 39(8): 126-135.
- SHEN B X, HUANG H Q. Research on surface defect detection of steel strip based on ESE-YOLO[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8):126-135.
- [21] 刘芷汐, 周春桂, 崔俊杰, 等. 基于改进 YOLOv5s 轻量化模型的红外场景目标检测方法研究[J]. 兵器装备工程学报, 2024, 45(3):323-330.
- LIU ZH X, ZHOU CH G, CUI J J, et al. Research on infrared scene target detection method based on improved YOLOv5s lightweight model[J]. Journal of Ordnance Equipment Engineering, 2024, 45 (3): 323-330.
- [22] ZHANG H, XU C, ZHANG SH J. Inner-IoU: More effective intersection over union loss with auxiliary bounding box [J]. ArXiv preprint arXiv: 2311.02877, 2023.
- [23] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.
- [24] 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 ZH 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.

作者简介

郭旭鹏(通信作者), 硕士研究生, 主要研究方向为计算机视觉。

E-mail:1835324609@qq.com

董立红, 博士, 教授, 主要研究方向为智能信息处理技术。

E-mail:1430315357@qq.com

秦映, 博士, 副教授, 主要研究方向为多源信息融合技术。

E-mail:qiny@xust.edu.cn