

# 轻量化 YOLO-SGLS 电梯钢丝绳损伤检测算法\*

江 敏 李志星 高雨晴 杨啸龙

(北京建筑大学机电与车辆工程学院 北京 100000)

**摘 要:**针对现有电梯钢丝绳表面损伤检测方法所存在的精度不足、计算量过大等缺陷,基于 YOLO11 算法提出一种轻量化 YOLO-SGLS 模型。首先采用 StarNet 替代 YOLO11 的主干网络,以星型运算提升特征提取和计算性能。同时,引入大核分离注意力(LSKA)模块与空间金字塔池化快速(SPPF)模块融合,利用深度卷积增强模型的特征表达与感知。此外,用动态卷积(DynamicConv)改进 Ghost 模块得到 GDC(ghost-dynamic-Conv)模块,并将其与 C3K2 结合,减少计算负担。最后设计轻量级共享卷积检没头(LSCD)提高推理速度。实验使用 Cable Damage 数据集,分训练、验证、测试集,在特定实验环境下,进行消融实验、泛化实验和对比实验。实验表明 YOLO-SGLS 模型相比原始基础网络 YOLO11n 的浮点计算量和参数量分别降低了 40%、36%,准确率提升了 5.5%,平均精度和召回率只下降了 0.3%、1.9%,在泛化能力测试中,100 张新数据集,YOLO-SGLS 正确识别的图像数为 77 张。证明了算法的轻量化程度、准确率和鲁棒性均满足电梯钢丝绳损伤检测在实际应用场景中的需求,尤其适用于资源受限的嵌入式设备。

**关键词:** 钢丝绳;损伤检测;YOLO11;轻量化;StarNet

中图分类号: TN762;TH164

文献标识码: A

国家标准学科分类代码: 460.4030

## Lightweight YOLO-SGLS Elevator Wire Rope Damage Detection Algorithm

Jiang Min Li Zhixing Gao Yuqing Yang Xiaolong

(School of Mechanical, Electrical and Vehicle Engineering, Beijing University of  
Civil Engineering and Architecture, Beijing 100000, China)

**Abstract:** A lightweight YOLO-SGLS model is proposed based on the YOLO11 algorithm to address the shortcomings of existing elevator wire rope surface damage detection methods, such as insufficient accuracy and excessive computational complexity. Firstly, StarNet is used to replace the backbone network of YOLO11, and the star operation is used to improve feature extraction and computational performance. Meanwhile, the LSKA module is integrated with SPPF to enhance the feature expression and perception of the model through deep convolution. In addition, the Ghost module is improved using DynamicConv to obtain the Ghost Dynamic Conv (GDC) module, which is combined with C3K2 to reduce computational burden. Finally, an LSCD detection head is designed to improve inference speed. The experiment uses the Cable Damage dataset, which is divided into training, validation, and testing sets. In a specific experimental environment, ablation experiments, generalization experiments, and comparative experiments are conducted. The experiment shows that the YOLO-SGLS model reduces GFLOPs and parameter count by 40% and 36% respectively compared to the original base network YOLO11, improves accuracy by 5.5%, and only decreases average accuracy and recall by 0.3% and 1.9%. In the generalization ability test, the YOLO-SGLS model correctly recognizes 77 images out of 100 new datasets. It has been proven that the lightweight, accuracy, and robustness of the algorithm meet the requirements of elevator wire rope damage detection in practical application scenarios, especially for embedded devices with limited resources.

**Keywords:** wire rope; defect detection; YOLO11; lightweight; StarNet

## 0 引言

钢丝绳作为关键的工业零部件,具有出色的疲劳强度、高抗拉强度、稳定的传动特性以及低噪声等特性<sup>[1]</sup>,因此被广泛应用于冶金、矿山、机械和建筑等领域,常见于汽车起重机、索道、电梯和矿井提升机等设备中。然而,鉴于钢丝绳使用频繁,需要长期承受高强度负荷,同时还会受到硬件的摩擦和环境的腐蚀,其表面出现损伤难以避免。现阶段,钢丝绳的损伤检测主要借助超声波、电磁、声波和 X 射线等物理传感器技术<sup>[2-5]</sup>。虽说这些方法在提升识别效率上比人工检测更具优势,可还是存在无法精准区分损伤类别,并且易受外界干扰等难题。

在计算机技术突飞猛进的当下,机器视觉在各类物体表面缺陷检测领域得以大规模运用。卷积神经网络(convolutional neural network, CNN)作为深度学习的重要应用,凭借其卓越的精度和强大的场景适应性,在目标检测领域取得了显著的进展<sup>[6-7]</sup>。依托 YOLO 目标检测算法的缺陷检测技术,借助高分辨率摄像头采集钢丝绳图像,再融合图像处理,能够迅速且精确地检测出缺陷<sup>[8-11]</sup>。在过往研究中,毛晓琦<sup>[12]</sup>提出运用 MobileNet 算法对 YOLOv3 进行轻量化处理,以此实现钢丝绳断丝检测。陈帅<sup>[13]</sup>通过结合结构重参数化的 RepVG 网络对 YOLOv5s 网络加以改进,在自制的钢丝绳表面缺陷数据集中取得了良好的检测效果。梁滨等<sup>[14]</sup>将深度可分离卷积与卷积块注意力模块(convolutional block attention module, CBAM)引入 YOLO 框架,减少了模型参数量并提升了对无用信息的关注度,基于此模型提出了一种曳引钢丝绳缺陷检测方案。刘晓磊等<sup>[15]</sup>利用高速摄像机对钢丝绳入井前段进行采样,提出了一种基于 YOLOv5 的物体表面小缺陷检测模型,并通过迁移学习方法进一步提升了小样本的精度。方旭东等<sup>[16]</sup>设计了 Swiener 滤波算法以修复钢丝绳图像中的运动模糊,成功减少了噪声干扰,并利用 RFC3 轻量化模块与 CBAM-R 注意力机制,提升了对小断口断丝的检测精度。李金华等<sup>[17]</sup>基于 YOLOv3 算法提出了一种智能钢丝绳检测方法,通过损伤系统,能够实时监测钢丝绳损伤情况并精确定位。Girshick<sup>[18]</sup>提出了一种新的训练算法解决了 R-CNN 和 SPP-net<sup>[19]</sup>的缺陷,使其成为一种新的单阶段训练方式,能够更新所有网络层,同时无需使用磁盘存储来缓存特征数据。随后,Redmon 等<sup>[19]</sup>提出的 YOLO 模型通过图像一次性处理后即能进行目标定位和识别,大大提高了效率。Liu 等<sup>[20]</sup>则在单发多框检测器(single shot multibox detector, SSD)中引入小型卷积滤波器,进一步提高了准确性,并满足了实时应用的需求。

综上所述,过往学者们在改进目标检测模型的训练

方式、检测效率与准确性等方面不断探索创新,取得了一系列成果。但是当前机器视觉模型在目标检测中仍然存在计算量大、特征提取能力不足等问题,本文基于最新的 YOLO11 框架提出了 YOLO-SGLS 模型。首先,采用 StarNet 替代传统的主干网络,通过星型运算提高了特征提取能力,并优化了计算性能。StarNet 能够有效地在低维输入空间中捕获复杂和高维的特征,从而增强了模型的表达能力。其次,在空间金字塔池化快速(spatial pyramid pooling-fast, SPPF)模块的基础上引入大核可分离注意力(large kernel separable attention, LSKA)模块,结合深度卷积与空间扩张卷积,增强了模型对长程依赖性和局部信息的感知能力,进一步提升了特征提取能力。为了降低计算负担,引入 GhostConv 模块以替代传统卷积操作,减少冗余特征的计算,提高了模型的效率和稳定性。最后,设计了轻量级共享卷积检测头(lightweight shared convolutional detection head, LSCD),通过减少参数量和计算量,提升了模型的推理速度,使其更适合嵌入式设备应用。

## 1 YOLO11 算法

电梯钢丝绳在服役过程中极易发生多种形式的损伤,主要包括断丝、磨损和腐蚀等,这些损伤大都出现在钢丝绳表面,特别是绳股的股峰部位,如图 1(a)所示。然而,钢丝绳的表面形态较为复杂,区别于一般的平面表面,如图 1(b)和(c)所示,且从灰度分布来看,损伤部位并不具有明显差异。传统的图像处理方法结合机器学习或数学建模往往依赖大量的先验知识。相比之下,最新的目标检测算法 YOLO11 能够直接进行损伤特征的自适应学习,自动分类和识别损伤类型,在实现从数据输入到结果输出的端到端检测方面,展现出巨大的潜力。

YOLO11 网络结构大体由 4 部分构成,输入端(input)、骨干网络(backbone)、颈部网络(neck)以及检测输出端(head),其网络结构如图 2 所示。

## 2 YOLO-SGLS 模型

在电梯钢丝绳损伤检测场景中,当直接将 YOLO11 应用于嵌入式在线监测设备时,遭遇了棘手难题。由于该模型本身参数繁多、计算量庞大,而嵌入式设备普遍资源受限、算力匮乏,导致二者难以适配。为化解这一矛盾,本文对 YOLOv11 的网络结构展开深度优化,改进后的网络命名为 YOLO-SGLS 模型,其结构如图 3 所示。通过替换 YOLO11 的主干网络为 StarNet,提升了特征提取能力,并优化了计算效率。此外,引入 LSKA 模块增强了模型的特征表达和感知能力,改进的 Ghost 模块替代了

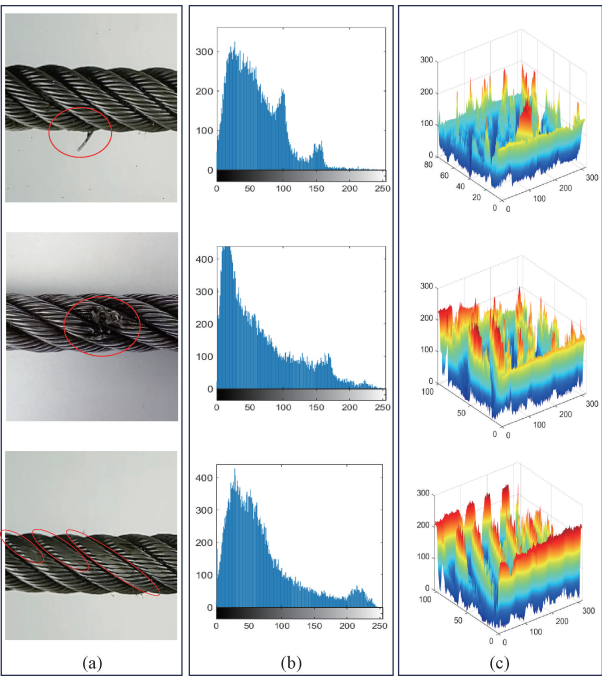


图 1 钢丝绳损失部位图及灰度图、三位灰度图  
Fig. 1 Steel wire rope damage location diagram and grayscale image, 3D grayscale image

C3K2 中的传统卷积操作,从而减少了计算负担,同时提升了精度。最后,采用了 LSCD 检测头,进一步提高了推理速度。

2.1 StarNet 网络

为了降低模型计算量与参数量,同时增强特征提取能力,本文提出使用 StarNet 替换 YOLO11 原本的主干部分。StarNet 网络通过引入星型运算 (StarOperation)<sup>[21]</sup> 具备了在维度较低的输入空间中获取高维度非线性特征的能力,以此提升网络的表达与计算效率。星型运算在输入特征图中进行元素乘法与求和运算,将输入映射至更高维非线性特征空间<sup>[22]</sup>。相较于传统矩阵乘法,它对计算性能的优化效果更加突出。

StarNet 将每层神经网络中的权重矩阵和偏差向量合并,表示为  $\{\mathbf{w}\} = \begin{bmatrix} \mathbf{Q} \\ \mathbf{B} \end{bmatrix}$ ,其中  $\mathbf{Q}$  代表权重,  $\mathbf{B}$  代表偏差。同时,扩展输入向量  $\mathbf{x} = \begin{bmatrix} \mathbf{X} \\ 1 \end{bmatrix}$ 。由此 StarNet 实现了星型运算  $(\mathbf{w}_1^T \mathbf{x}) \times (\mathbf{w}_2^T \mathbf{x})$ 。在单输入单输出的场景下,定义  $\mathbf{w}_1$  和  $\mathbf{w}_2, \mathbf{x} \in R^{(d+1) \times 1}$ ,其中  $d$  为输入通道数。星型运算的表达式如下:

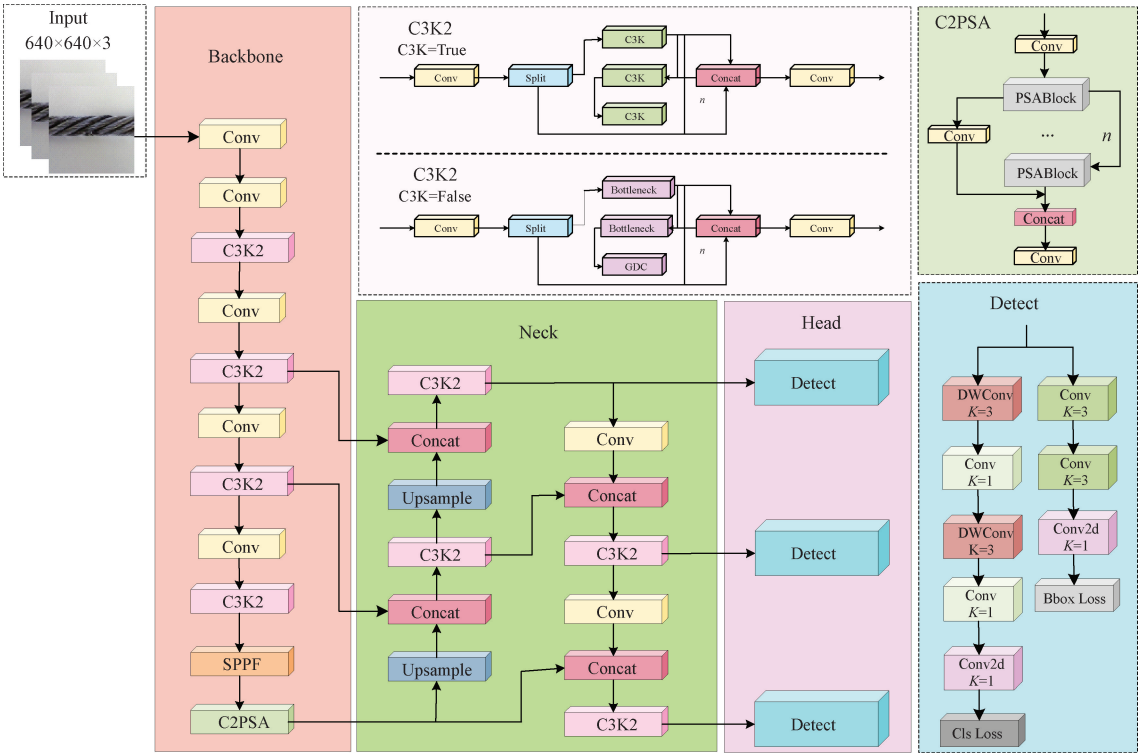


图 2 YOLO11 网络结构  
Fig. 2 YOLO11 network structure diagram

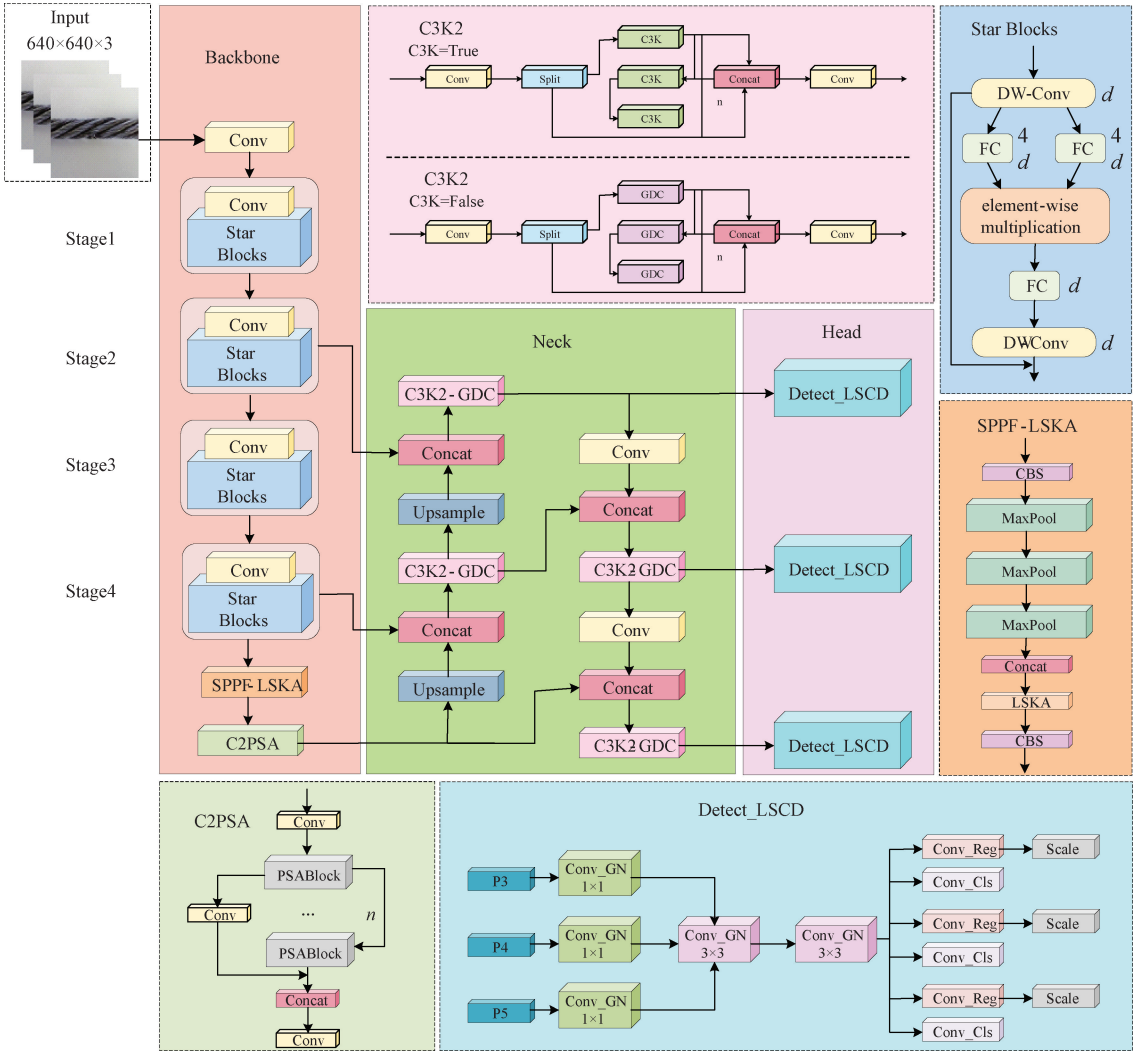


图 3 YOLO-SGLS 网络结构

Fig. 3 YOLO-SGLS network structure diagram

$$\mathbf{w}_1^T \mathbf{x} \times \mathbf{w}_2^T \mathbf{x} = \left( \sum_{i=1}^{d+1} \mathbf{w}_1^i \mathbf{x}^i \right) \times \left( \sum_{j=1}^{d+1} \mathbf{w}_2^j \mathbf{x}^j \right) =$$

$$\sum_{i=1}^{d+1} \sum_{j=1}^{d+1} \mathbf{w}_1^i \mathbf{w}_2^j \mathbf{x}^i \mathbf{x}^j = \alpha_{(1,1)} \mathbf{x}^1 \mathbf{x}^1 + \dots + \alpha_{(d+1,d+1)} \mathbf{x}^{d+1} \mathbf{x}^{d+1}$$

$$(1)$$

$$\alpha_{(i,j)} = \begin{cases} \mathbf{w}_1^i \mathbf{w}_2^j, & i = j \\ \mathbf{w}_1^i \mathbf{w}_2^j + \mathbf{w}_1^j \mathbf{w}_2^i, & i \neq j \end{cases} \quad (2)$$

式中:  $i$  和  $j$  用于通道索引;  $\alpha$  代表各项的系数。星型运算最终可以展开成  $\frac{(d+2)(d+1)}{2}$  种不同的项目组合(式(1))。隐藏维度会随着叠加层数以递归形式扩大至接近无穷大。式(3)为星型运算迭代公式,  $S_n$  为第  $n$  次迭代的输出。

$$S_1 = \sum_{i=1}^{d+1} \sum_{j=1}^{d+1} \mathbf{w}_{(1,1)}^i \mathbf{w}_{(1,2)}^j \mathbf{x}^i \mathbf{x}^j$$

$$S_2 = \mathbf{W}_{2,1}^T S_1 \times \mathbf{W}_{2,2}^T S_1$$

$$S_3 = \mathbf{W}_{3,1}^T S_2 \times \mathbf{W}_{3,2}^T S_2$$

$$\vdots$$

$$S_n = \mathbf{W}_{n,1}^T S_{n-1} \times \mathbf{W}_{n,2}^T S_{n-1} \quad (3)$$

星型运算通过多层叠加,能逐步递增隐藏维度,递归形成高维特征表示,大幅提升网络能力。多次迭代后,其输出维度呈指数级增加,不断拓展特征空间。基于此,仅需叠加几层星型运算,潜在维度就能指数级放大。叠加 StarBlock 形成 StarNet,如图 4 所示。StarNet 的简洁结构大大降低了计算成本,很适合解决本文所提问题。具体做法是,叠加 4 个 StarBlock 替换 YOLO11n 主干网络中的对应阶段,通过星形运算实现低维高效的特征融合。

## 2.2 LSKA 模块

YOLO11 的空间金字塔池化融合结构是将特征融合模块加入空间金字塔池化(SPP)模块的得到的。该模块会针对输入特征图进行不同尺度的池化操作,然后通过



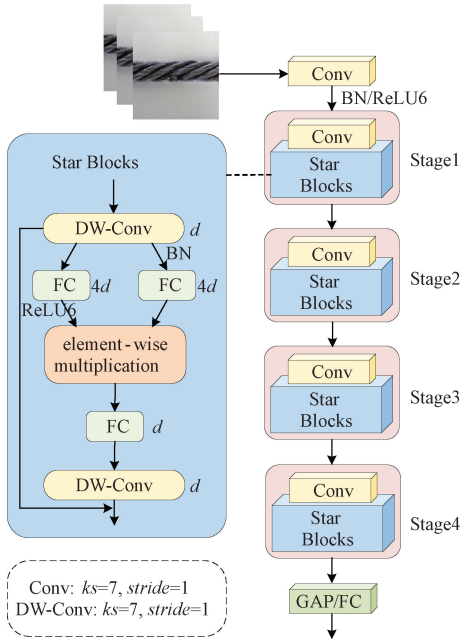


图 4 StarNet 结构

Fig. 4 StarNet structure diagram

卷积来融合这些池化结果以生成特征图。这种方式使模块在进行特征提取时具备一定的自适应能力。然而,实验表明,当它应用于小目标钢丝绳损伤检测时,SPPF 会提取过多的局部信息使得全局信息遭到损失,要平衡局部与全局信息获取需对模块进行改进。为此,引入了大核注意力 (large kernel attention, LKA) 的可分离版本,即 LSKA,LSKA 通过标准深度卷积 (depthwise convolution, DW-Conv) 获取局部信息,再借助深度膨胀卷积 (depthwise dilated convolution, DW-D-Conv) 来模拟长程依赖关系。与 LKA 的区别在于 LSKA 将二维卷积核分解为级联的垂直一维和水平一维卷积核,这种分解方法极大降低了参数量和计算量,同时增强了模型对重要特征的关注能力,从而提升了整体性能<sup>[23]</sup>。LKA 的结构如图 5(a) 所示,而 LSKA 的结构如图 5(b) 所示。

因此,本文将 LSKA 引入 SPPF,提出了一种名为 SPPF-LSKA 的新模块。如图 5(c) 所示,SPPF 融合后的特征图,经级联的垂直一维和水平一维卷积及深度膨胀卷积,获取上下文信息并实现长程依赖。随后,输出注意力图,再将其与输入特征相乘,自适应细化特征,提升表达与感知能力。而且一维内核的设计不会使模型计算量增加。LSKA 模块的输出如下:

$$\mathbf{x}^c = \sum_{H,W} \mathbf{I}_{(2d-1) \times 1}^C * \left( \sum_{H,W} \mathbf{I}_{1 \times (2d-1)}^C * \mathbf{F}^C \right) \quad (4)$$

$$\mathbf{Z}^c = \sum_{H,W} \mathbf{I}_{\left[\frac{k}{d}\right] \times 1}^C * \left( \sum_{H,W} \mathbf{I}_{1 \times \left[\frac{k}{d}\right]}^C * \mathbf{X}^C \right) \quad (5)$$

$$\mathbf{A}^c = \mathbf{I}_{1 \times 1} * \mathbf{Z}^c \quad (6)$$

$$\mathbf{T}^c = \mathbf{A}^c \otimes \mathbf{F}^c \quad (7)$$

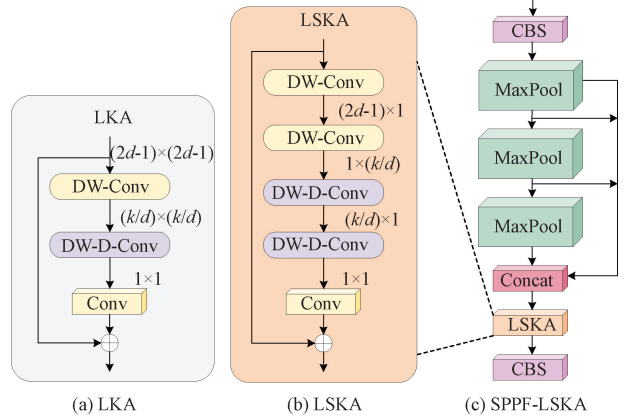


图 5 LKA 结构,LSKA 结构和 SPPF-LSKA 结构

Fig. 5 LKA structure diagram, LSKA structure diagram and SPPF-LSKA structure diagram

式中: \* 和  $\otimes$  分别代表卷积和哈达玛乘积;  $d$  代表膨胀率;  $\mathbf{x}^c$  代表内核大小  $(2d-1) \times (2d-1)$  的深度卷积的输出,通过将大小为  $k \times k$  的核与输入特征图进行卷积得到的深度卷积的输出  $\mathbf{Z}^c$ ,对其使用  $1 \times 1$  卷积得到注意力图  $\mathbf{A}^c$ 。 $\mathbf{F}$  中的各个通道  $C$  都与核  $\mathbf{I}$  中的对应通道进行卷积。LSKA 的输出  $\mathbf{T}^c$  是注意力图  $\mathbf{A}^c$  和输入特征图  $\mathbf{F}^c$  的哈达玛乘积。这种改进不仅优化了多尺度特征的提级,还通过改进特征融合机制增强了模型对不同缺陷的检测适应性,从而能够高效识别不同尺寸和类型的钢丝绳损伤<sup>[24]</sup>。

### 2.3 改进的 Ghost 模块

Han 等<sup>[25]</sup>提出的 Ghost 模块是一种通过减少参数数量和计算负载来提高模型效率的技术。这是通过使用更少的卷积核来实现的,通常是原来的  $1/2$ ,同时保持甚至增强特征图表达能力。

假设输入特征的高、宽和通道数分别为  $h, w$  和  $c$ ,输出特征的高度和宽度为  $H$  和  $W$ ,卷积核的大小为  $k$ ,卷积核的数量为  $n$ ,线性变换卷积核大小为  $d$ ,变换数量为  $s$ 。普通卷积与 Ghost 模块的计算量和参数量之比<sup>[26]</sup>  $r_s$  和  $r_c$  的计算如式(8)、(9)所示。

$$r_s = \frac{h \times w \times c \times H \times W \times n}{\frac{n}{s} \times H \times W \times k \times k \times c + (s-1) \times \frac{n}{s} \times H \times W \times d \times d} = \frac{c \times k \times k}{\frac{1}{s} \times c \times k \times k + \frac{(s-1)}{s} \times d \times d} \approx s \quad (8)$$

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

$$\frac{s \times c}{s + c - 1} \approx s \quad (9)$$

由式(8)、(9)可知,Ghost 模块计算量和参数数量都约是普通卷积的  $1/s$ 。

动态卷积 (DynamicConv) 属于特定的动态感知器,目的在于契合计算约束。它由  $K$  个共享卷积核组成,这些大小、维度相同的卷积核通过注意力权重  $\{\pi_k(x), \pi_k\}$  动态聚合。通过挤压与激励方法算出卷积核的注意力,再经全局平均池化和全连接层,生成归一化的注意力权重。由此,动态卷积能够依据输入,动态地选择并聚合卷积核,提升模型的表达能力。

如果在 Ghost 模块中引入动态卷积,可以借助动态卷积相较普通卷积更强的特征表达能力,既能解决普通卷积特征提取的局限,又能保持 Ghost 模块低参数量与计算复杂度的优势。改进后的 Ghost 模块 Ghost 动态卷积 (ghost-dynamic convolution, GDC) 如图 6 所示。

GDC 模块通过线性操作以低成本的方式解决特征冗余的问题,避免信息丢失,在小目标检测中,主干网络




图 6 GDC 模块

Fig. 6 GDC module

负责特征提取,丢失冗余信息会严重影响特征学习。所以本文采用 GDC 模块替代原始 C3k2 模块中的 Conv 模块,既能削减模型计算量,还能稳定保证精度。

YOLO11 的 C3K2 模块使用常规卷积模块连接 Bottleneck 模块。尽管 Bottleneck 模块能够更好地融合不同尺度的信息,但整体的计算强度仍然很高,还加深了网络的深度。因此,本文提出用 GDC 模块替换 C3K2 和 C3K 中原有的 Bottleneck 模块,生成 C3K2-GDC 和 C3K-GDC 模块,从而完成了与 C3K2 模块的融合,C3K2-GDC、C3K-GDC 与 GDC 模块结构如图 7 所示。

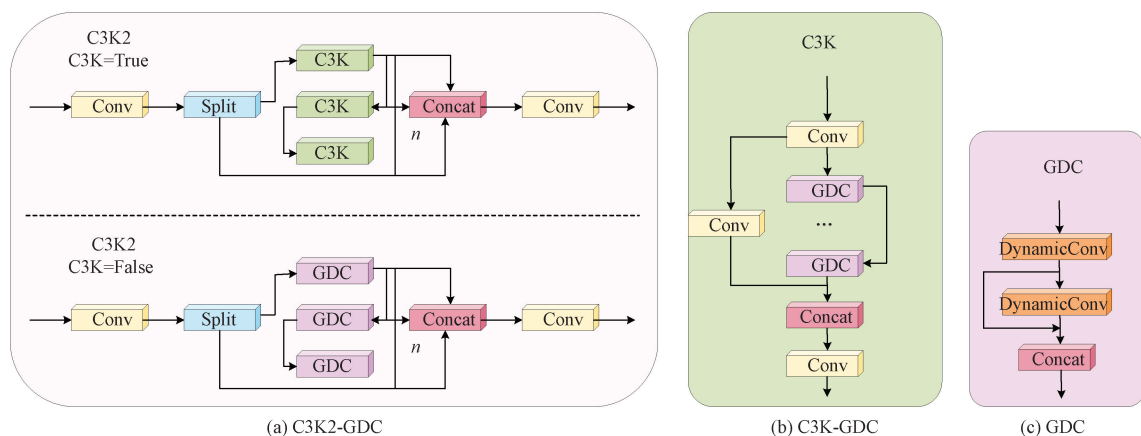


图 7 C3K2-GDC 结构,C3K-GDC 结构和 GDC 结构

Fig. 7 C3K2-GDC structure diagram, C3K-GDC structure diagram and GDC structure diagram

## 2.4 LSCD

YOLO11 的检测头采用主流的解耦头结构,将分类和检测分支分开。每个分支由两个  $3 \times 3$  卷积层和一个  $1 \times 1$  卷积层组成。这种结构的参数数量比较大,在嵌入式设备的资源受限情景中会限制 YOLO11 性能发挥。为此,本文引入了 LSCD 检测头,在降低参数和计算复杂度的同时,提高识别速度,保持识别精度<sup>[27]</sup>。

LSCD 检测头的结构如图 8 所示。首先使用 3 个  $1 \times 1$  卷积层分别对输入特征层进行通道调整,调整后的通道数为中间层通道数,记作  $chide$ 。接着,所有特征层由共享的  $3 \times 3$  卷积核模块提取特征,最后,分离回归分支与分类分支。回归分支用  $1 \times 1$  卷积预测边

界框坐标偏移。经 Scale 层调整尺度以应对目标大小不一的情况;分类分支则用另一个  $1 \times 1$  卷积预测类别概率,两分支卷积层权重独立,便于模型分别学习定位与分类。




图 8 LSCD 模块

Fig. 8 LSCD module

共享权重设计显著减少了冗余参数,使得 LSCD 检测头在资源受限的场景中尤为适用<sup>[28]</sup>。这种设计可以同时处理不同尺度的特征,进而显著提高模型的运行速度。将 LSCD 应用于电梯钢丝绳损伤检测中,能大幅提升检测速度和模型整体适用性。

3 实验分析与讨论

3.1 实验数据集

为验证本文提出的 YOLO-SGLS 的成效,本文使用了 RoboflowCable 数据集,经过数据增强并重新标记制作了一个新数据集——Cable Damage。数据集中包括断丝、磨损和腐蚀三种常见钢丝绳缺陷,共有 13 222 张图片。数据集按 87%、9%、4%的比例,分为训练集、验证集与测试集,分别含 11 569 张、1 102 张、551 张图片。训练集用于训练模型,让模型通过不断调整自身参数以最小化损失函数,而验证集用来评估模型在不同超参数设置下的性能表现,辅助判断模型是否存在过拟合或欠拟合,进而对模型进行优化调整,测试集旨在对训练和优化后的模型进行最终评估,以其测试结果衡量模型在实际电梯钢丝绳缺陷检测场景中的可用性与可靠性。3 种缺陷类型如图 9 所示。




图 9 数据集中 3 种损坏类型

Fig. 9 Three types of corruption in the dataset

3.2 实验配置

实验环境如表 1 所示,训练模型时,设定基本参数如下:迭代 300 次,每批次数据量为 16。将输入图像统一调

整为 640×640 尺寸后做归一化处理。在优化器的选择上,采用了随机梯度下降(SGD),并搭配线性学习率调度策略。其中,初始学习率设为 0.01,最终学习率逐步降至 0.000 1。为了加快训练进程,将 warm\_epochs 设置为 3.0,动量参数设置为 0.8,同时把权重衰减系数设定为 0.000 5。

表 1 实验环境

Table 1 Experimental environment

名称	环境参数
操作系统	Windows 10 64 位
CPU	Intel(R) Xeon(R) Platinum 8352V
GPU	RTX 4090(24 GB)
内存	90 GB
Python	3.10(ubuntu22.04)
Pythorch	2.10
Cuda	12.1

3.3 评价指标

当前,目标检测模型的计算效率和存储效率主要通过参数量、千亿次浮点运算量((giga floating-point operations per second,GFLOPs)和帧率来衡量。参数量指的是模型中可训练参数的总量,这些参数涵盖了神经网络中的权重和偏置等。参数量越大,模型理论上的表达能力可能越强,但同时也意味着更大的资源需求。千亿次浮点运算量则反映了模型在进行一次前向传播或训练迭代时,大致需要执行的浮点运算次数。它是衡量模型计算复杂度的重要指标。帧率代表模型每秒能够处理的图像帧数。较高的帧率意味着模型能够在单位时间内处理更多的图像,实时性更强。

而模型的精确度通常通过精确率(Precision)来评判,计算公式如式(10)所示。

$$Precision = \frac{TP}{TP + FP}$$
 (10)

式中:TP 为真正例,即正确预测为正例的样本数;FP 为假正例。TP 不变的情况下,FP 随着 Precision 的增大减少,即模型误报情况减少。

表 2 消融实验

Table 2 Ablation experiment

试验	StarNet	SPPF-LSKA	C3K2-GDC	LSCD	浮点运算量/ GFLOPs	参数量/ (×10 <sup>6</sup> )	mAP@ 0.5/%	帧率/fps	Precision/%	Recall/%
1	×	×	×	×	6.3	2.58	79.5	909	80.3	74.5
2	√	×	×	×	5.0	1.94	78.1	833	83.6	70.8
3	×	√	×	×	6.5	2.85	79.3	556	82.8	72.4
4	×	×	√	×	5.4	2.22	79.2	416	84.6	71.2
5	×	×	×	√	5.6	2.42	80.5	909	86	73.2
6	√	√	×	×	5.0	2.01	76.7	769	81	70.1
7	√	×	√	√	3.8	1.59	77.4	833	82.6	71.1
8	√	√	√	√	3.8	1.66	79.2	833	85.8	72.6

注:√使用该算法;×不使用该算法



召回率 (recall) 的计算公式如式 (11) 所示。

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

(11)

式中:FN (False Negative) 为假负例,它随着 Recall 的增大而减少,模型将正例误判为负例的情况变少,即模型漏报情况减少。

平均精度均值 (mAP) 的计算公式如式 (12) 所示。

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

(12)

式中:mAP 是所有类别平均精度 (average precision, AP) 的平均值。AP 用于衡量识别单一类别的准确性,而 mAP 则综合了所有类别的 AP,用于评估模型的整体性能。mAP 值的提高意味着精确率-召回率 (PR) 曲线下方的面积增大,从而反映出模型在各类别上的综合表现有所提升。mAP@0.5 是在交并比 (IoU) 阈值为 0.5 时计算的 mAP。

3.4 消融实验

采用消融实验验证法对 StarNet 模块、SPPF-LSKA 模块、C3K2-GDC 模块以及 LSCD 模块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。由实验结果可知,各模块对模型优化成效显著。引入 StarNet 模块,浮点运算量降低约 20.6%,参数量减少约 24.8%,精确率升至 83.6%,在轻量化同时提升检测效果;SPPF-LSKA 模块虽使浮点运算量略增,但 mAP@0.5 达 79.3%,精确率、召回率均改善,增强了特征提取能力;C3K2-GDC 模块轻量化突出,浮点运算量降至 5.4 GFLOPs,参数量减至  $2.22 \times 10^6$ ,检测精度与召回率维持良好;LSCD 模块在轻量化基础上,mAP@0.5 提至 80.5%,精确率、召回率显著提升。模块组合效果亦佳,StarNet 与 SPPF-LSKA 结合展现了轻量化的协同作用;StarNet 与 C3K2-GDC 结合强化了轻量化与检测表现;三者结合时,浮点运算量为 3.8 GFLOPs,参数量为  $1.66 \times 10^6$ ,mAP@0.5 达 79.2%,达成模型轻量化与性能提升的平衡,各模块及组合优化效果明显。

3.5 泛化能力与鲁棒性评估

在目标检测领域,模型泛化能力体现于模型在新数据集上的识别表现,鲁棒性体现为不同场景下模型的稳定性,常通过模型对不同角度和复杂背景图片的识别能力衡量。为评估本文模型的泛化能力与鲁棒性,选取 100 张未参与训练的涵盖不同角度的钢丝绳损伤图像,用本文模型检测,结果如表 3 所示。

从表 3 的实验结果可以看出,本文模型在新数据集上的识别准确率最高,泛化能力与鲁棒性最强。部分识别效果的对比展示如图 10 所示,包括倾斜和水平角度的对比(图 10 (a) 和 (b))、图片模糊时的缺陷检测对比(图 10 (c)) 以及多根钢丝绳缺陷检测的对比(图 10 (d))。

比(图 10(d))。

表 3 泛化实验

试验	正确识别/张
YOLO11n	70
YOLO11n+ StarNet	59
YOLO11n+ LSKA	64
YOLO11n+ GDC	67
YOLO11n+ LSCD	79
YOLO11n+ StarNet+ LSKA	70
YOLO11n+ StarNet+ GDC + LSCD	71
YOLO-SGLS	77




图 10 新数据集识别效果

Fig. 10 New dataset recognition effect image

模型对不同拍摄视角下的钢丝绳缺陷均可精准检测,标注框与损伤区域高度贴合,说明模型的多尺度特征提取模块可突破视角限制,通过动态捕捉空间维度特征差异,适配多种复杂工况。



3.6 对照实验及分析

为全方位评估本文模型的优化成效,本文挑选多个极具代表性的目标检测模型,与改进后的模型展开对比分析。在一阶段目标检测模型方面,选取了广泛应用的 YOLOv5n、YOLOv8n,以及经典的 SSD 模型。针对 SSD,还特别考量了其采用不同骨干网络时的性能差异,即分别基于 VGG 和 Mobilenet 的版本。为实现多维度对比,还纳入了双阶段检测的经典之作 Faster-RCNN。为探究不同骨干网络对其性能的影响,本文测试了使用 VGG 和 Resnet 骨干网络的 Faster RCNN 模型。同时,为紧跟目标检测领域的前沿技术趋势,加入了基于 DETR 架构的高效单阶段检测模型 RT-DETR-R18 和 STD-DETR。

在整个实验过程中,始终严格把控实验条件,确保各模型在相同环境下进行测试。选用 Cable Damage 数据集,从精确度、参数量以及计算量等关键指标,全面评估各个模型在边缘设备上部署后的性能表现。详细实验结果如表 4 所示,以便直观对比分析各模型的优劣。

从实验结果看,在 mAP@0.5 指标上,YOLO-SGLS 算法以 79.2% 的成绩,仅次于 STD-DETR 的 82.5% 和 RT-DETR-R18 的 79.7%,领先于 RT-DETR-R18 的 79.7% 以及其他传统算法,展现出较高的检测精度。参数量方面,本文算法仅  $1.66 \times 10^6$ ,远低于 Faster-RCNN (VGG) 的  $137.17 \times 10^6$ 、Faster-RCNN (ResNet) 的  $28.53 \times$

$10^6$  等算法,相比轻量级的 YOLOv5n 和 SSD (MobileNet) 也更低,模型极为轻量化。在计算复杂度指标上,浮点运算量为 3.8 GFLOPS,数据表现十分突出,远低于 Faster-RCNN (ResNet) 的 941.4、RT-DETR-R18 的 110.0 等,相较于 YOLOv8n 和 YOLO\_BF 同样更低。综合来说,YOLO-SGLS 在保证较高检测精度的同时,兼具模型轻量化与低计算复杂度特性,在资源受限环境中具有显著优势,能有效满足实际应用需求。

表 4 对照实验

Table 4 Controlled experiment

模型	mAP@0.5/%	参数量/( $\times 10^6$ )	浮点运算量/GFLOPs
YOLOv5n	59.0	1.98	4.5
YOLOv8n	55.6	3.23	8.7
YOLO_BF	62.3	2.74	8.0
SSD (VGG)	65.8	26.49	62.7
SSD (Mobilenet)	63.6	6.20	1.8
Faster-RCNN (VGG)	71.2	137.2	370.2
Faster-RCNN (Resnet)	75.3	28.5	941.4
RT-DETR-R18	79.7	31.96	110.0
STD-DETR	82.5	41.38	124.4
YOLO-SGLS	79.2	1.66	3.8

为更直观呈现 YOLO-SGLS 算法与其他主流目标检测算法检测效果差异,将不同钢丝绳外观、角度、背景环境、光照条件的检测结果进行对比如图 11 (a) ~ (h) 所示。




图 11 检测效果对比

Fig. 11 Comparison chart of detection effect

相较于其他主流目标检测算法存在漏检、误报的情况, YOLO-SGLS 具备出色的环境鲁棒性。无论处于背景干扰、光照波动的复杂环境, 或是面对钢丝绳外观形态、拍摄角度的变化, 均能稳定输出高精度检测结果。

## 4 结 论

本文提出 YOLO-SGLS 模型, 通过引入创新的模块设计和优化策略, 有效提升了钢丝绳表面缺陷检测的精度与效率。首先, StarNet 替代传统主干网络, 通过星型运算显著增强了特征提取能力, 优化了计算性能; 其次, 在 SPPF 模块基础上引入 LSKA 模块, 改善了长程依赖性与局部信息的处理, 进一步提升了特征感知能力; 同时, 通过引入 GhostConv 模块, 减少了冗余特征的计算负担, 提高了模型的效率与稳定性; 最后, 设计了轻量级共享卷积检测头 LSCD, 降低了计算和参数量, 提升了推理速度。

实验表明 YOLO-SGLS 模型相比原始基础网络 YOLO11n 的浮点运算量和参数量分别降低了 40%、36%, 模型大小仅为  $1.66 \times 10^6$ , 准确率提升 5.5%, 达到 85.8%, 平均精度和召回率只下降了 0.3%、1.9%, 在轻量化的同时, 最大程度上降低了模型的漏检率。在泛化能力测试中, 100 张新数据集, YOLO-SGLS 正确识别的图像数为 77 张高于 YOLO11n 的 70 张。验证了算法的轻量化程度、准确率和鲁棒性均满足电梯钢丝绳损伤检测在实际应用场景中的需求, 在未来的工作中, 将在电梯钢丝绳在线监测的嵌入式设备中植入 YOLO-SGLS 算法, 对其落地部署进行研究。

## 参考文献

- [1] 袁方, 胡斌梁, 周知进. 在役钢丝绳缺陷检测方法的研究现状与展望[J]. 机械设计与制造, 2010(2): 260-262.  
YUAN F, HU B L, ZHOU ZH J. An analysis on the research status quo and prospects of defect detection methods of wire ropes [J]. Machinery Design&Manufacture, 2010(2): 260-262.
- [2] 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.  
GAO SH, WANG Q H, FU D D, et al. Hyperspectral imaging non-destructive detection of sugar content and hardness of red seedless grapes[J]. Acta Optica Sinica, 2019, 39(10): 347-356.
- [3] YAN X, ZHANG D, PAN S, et al. Online nondestructive testing for fine steel wire rope in electromagnetic interference environment[J]. NDT and E

- International, 2017, 92: 75-81.
- [4] 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.  
ZHANG X P, HUANG L X, SHEN J H, et al. Analysis of acoustic emission signal propagation characteristics of wire ropes[J]. Failure Analysis and Prevention, 2022, 17(1): 24-31, 36.
- [5] 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.
- [6] ZHANG M C, SHI H, ZHANG Y, et al. Deep learning-based damage detection of mining conveyor belt [J]. Measurement, 2021, 175: 109130.
- [7] YAO Z, HE D, CHEN Y, et al. Inspection of exterior substance on high-speed train bottom based on improved deep learning method [J]. Measurement, 2020, 163: 108013.
- [8] 王德伟, 刘小芳. 基于改进 YOLOv8n 的带钢表面缺陷检测方法[J]. 国外电子测量技术, 2024, 43(7): 158-169.  
WANG D W, LIU X F. Surface defect detection method of strip steel based on improved YOLOv8n[J]. Foreign Electronic Measurement Technology, 2024, 43(7): 158-169.
- [9] 张涛, 谢探阳, 李玉梅, 等. 基于改进 YOLOv4 算法的玻璃杯缺陷识别方法研究[J]. 电子测量技术, 2023, 46(2): 46-51.  
ZHANG T, XIE T Y, LI Y M, et al. Research on glass cup defect recognition method based on improved YOLOv4 algorithm [J]. Electronic Measurement Technology, 2023, 46(2): 46-51.
- [10] 伍济钢, 成远, 邵俊, 等. 基于改进 YOLOv4 算法的 PCB 缺陷检测研究[J]. 仪器仪表学报, 2021, 42(10): 171-178.  
WU J G, CHENG Y, SHAO J, et al. Research on PCB defect detection based on improved YOLOv4 algorithm[J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 171-178.
- [11] 赵佰亭, 张晨, 贾晓芬. ECC-YOLO: 一种改进的钢材表面缺陷检测方法[J]. 电子测量与仪器学报, 2024, 38(4): 108-116.  
ZHAO B T, ZHANG CH, JIA X F. ECC-YOLO: An

- improved method for surface defect detection of steel[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 108-116.
- [12] 毛晓琦. 钢绳表面缺陷的视觉检测方法研究[D]. 西安:西安理工大学, 2021.
- MAO X Q. Research on visual inspection methods for surface defects of steel ropes [D]. Xi'an: Xi'an University of Technology, 2021.
- [13] 陈帅. 基于深度学习的钢丝绳表面缺陷检测模型改进算法研究[D]. 西安:西安理工大学, 2024.
- CHEN SH. Research on improved algorithm for surface defect detection model of wire ropes based on deep learning [D]. Xi'an: Xi'an University of Technology, 2024.
- [14] 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, 8.
- LIANG B, SONG X F, GAO J, et al. Defect detection method for traction wire ropes based on YOLO algorithm framework[J]. Nondestructive Testing, 2023, 47(6): 1-4, 8.
- [15] 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 coal mine wire rope defect detection method based on deep learning[J]. Coal Engineering, 2023, 55(11): 148-153.
- [16] 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 lightweight mine wire rope broken wire detection algorithm based on attention mechanism[J]. China Coal, 2024, 50(8): 152-164.
- [17] 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, 21.
- LI J H, XIA L M. Application of image recognition technology in mine wire rope detection [J]. Shanxi Coking Coal Science & Technology, 2022, 46(4): 16-18, 21.
- [18] GIRSHICK B R. Fast R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [19] REDMON J, DIVVALA K S, GIRSHICK B R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [20] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision. Cham: Springer International Publishing, 2016: 21-37.
- [21] MA X, DAI X, BAI Y, et al. Rewrite the stars [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [22] 沈骞, 张磊, 张宇翔, 等. 基于改进 YOLOv8n 的轻量化分心驾驶行为检测方法[J]. 电子测量技术, 2024, 47(24): 65-75.
- SHEN Q, ZHANG L, ZHANG Y X, et al. A lightweight distracted driving behavior detection method based on improved YOLOv8n [J]. Electronic Measurement Technology, 2024, 47(24): 65-75.
- [23] 高民, 陈高华, 古佳欣, 等. FLM-YOLOv8: 一种轻量级的口罩佩戴检测算法[J]. 计算机工程与应用, 2024, 60(17): 203-215.
- GAO M, CHEN G H, GU J X, et al. FLM-YOLOv8: A lightweight mask wearing detection algorithm [J]. Computer Engineering and Applications, 2024, 60(17): 203-215.
- [24] SUN Q, NOCHE B, XIE Z, et al. Research on seamless fabric defect detection based on improved YOLOv8n [J]. Applied Sciences, 2025, 15(5): 2728-2728.
- [25] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference On Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [26] 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. A detection algorithm for wire rope damage in coal mines based on YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(9): 120-128.
- [27] 邓天民, 陈月田, 余洋, 等. 聚焦形状特征的路面病害检测算法[J]. 计算机工程与应用, 2024, 60(24): 291-305.
- DENG T M, CHEN Y T, YU Y, et al. Pavement disease detection algorithm focusing on shape features [J]. Computer Engineering and Applications, 2024, 60(24):

291-305.

[28] MENG R, WANG J, HUANG Y, et al. LSCD-Pose: A feature point detection model for collaborative perception in airports[J]. Sensors, 2025, 25(10): 3176-3176.

作者简介



江敏, 2022 年于辽宁石油化工大学获得学士学位, 现为北京建筑大学研究生, 主要研究方向为智能装备运维与大数据分析。  
E-mail: jm18940371327@163.com

**Jiang Min** received the B. Sc. degree from Liaoning Petrochemical University in 2022. She is now a M. Sc. candidate at Beijing University of Civil Engineering and Architecture. Her main research interest includes intelligent equipment operation and maintenance and big data analysis.



李志星 (通信作者), 2008 年于河北工程大学获得学士学位, 2011 年于内蒙古科技大学获得硕士学位, 2018 年于北京科技大学获得博士学位, 现为北京建筑大学副教授、硕士生导师, 主要研究方向为信号处理和机电装备故障大数据分析 with 智能诊断。  
E-mail: onyxlzx@126.com

**Li Zhixing** (Corresponding author) received his B. Sc. degree from Hebei University of Engineering in 2008, M. Sc. degree from Inner Mongolia University in 2011, and Ph. D. degree from University of Science and Technology Beijing in 2018, respectively. Now he is an associate professor in Beijing University of Civil Engineering and Architecture. His main research interests include Signal processing and electromechanical equipment failure big data analysis and intelligent diagnosis.