

# 光电工程

## Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊  
Scopus CSCD

### 基于改进YOLOv5s网络的斜拉桥拉索表面缺陷检测

王鹏峰, 李运堂, 黄永勇, 朱文凯, 林婕, 王斌锐

#### 引用本文:

王鹏峰, 李运堂, 黄永勇, 等. 基于改进YOLOv5s网络的斜拉桥拉索表面缺陷检测[J]. 光电工程, 2024, 51(5): 240028.

Wang P F, Li Y T, Huang Y Y, et al. Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network[J]. *Opto-Electron Eng*, 2024, 51(5): 240028.

<https://doi.org/10.12086/oee.2024.240028>

收稿日期: 2024-01-26; 修改日期: 2024-04-19; 录用日期: 2024-04-24

### 相关论文

#### 改进GBS-YOLOv7t的钢材表面缺陷检测

梁礼明, 龙鹏威, 卢宝贺, 李仁杰

光电工程 2024, 51(5): 240044 doi: [10.12086/oee.2024.240044](https://doi.org/10.12086/oee.2024.240044)

#### PAW-YOLOv7: 河道微小漂浮物检测算法

栾庆磊, 常昕昱, 吴叶, 邓从龙, 史艳琼, 陈梓华

光电工程 2024, 51(4): 240025 doi: [10.12086/oee.2024.240025](https://doi.org/10.12086/oee.2024.240025)

#### 局部和全局特征融合的太阳能电池片表面缺陷检测

陶志勇, 何燕, 林森, 易廷军, 张尧晟

光电工程 2024, 51(1): 230292 doi: [10.12086/oee.2024.230292](https://doi.org/10.12086/oee.2024.230292)

#### 基于改进YOLOv5s的无人机图像实时目标检测

陈旭, 彭冬亮, 谷雨

光电工程 2022, 49(3): 210372 doi: [10.12086/oee.2022.210372](https://doi.org/10.12086/oee.2022.210372)

更多相关论文见光电期刊集群网站 



<http://cn.oejournal.org/oee>



OE\_Journal



Website



DOI: 10.12086/oee.2024.240028

## 基于改进 YOLOv5s 网络的 斜拉桥拉索表面缺陷检测

王鹏峰<sup>1</sup>, 李运堂<sup>2\*</sup>, 黄永勇<sup>2</sup>, 朱文凯<sup>2</sup>,  
林 婕<sup>2</sup>, 王斌锐<sup>2</sup>

<sup>1</sup>中国计量大学现代科技学院, 浙江金华 322002;

<sup>2</sup>中国计量大学机电工程学院, 浙江杭州 310018

**摘要:** 针对人工检测斜拉桥拉索表面缺陷效率低、安全性差, 而现有目标检测方法速度慢、精度低, 受拉索表面污垢干扰容易导致错检、漏检等问题, 本文改进 YOLOv5s 网络以实现拉索表面缺陷快速准确检测。在主干网络增加 TRANS 模块, 获取单幅图像更多特征, 提高缺陷检测精度; 为减少参数量、提高计算速度, 将颈部网络的 CSP 模块替换为 GhostBottleneck 模块, 同时利用深度可分离卷积代替普通卷积; 利用 SIOU 损失函数减少边界框震荡, 提高预测框和真实框重叠度计算结果准确性, 增加模型稳定性。实验结果表明: 改进 YOLOv5s 网络的 mAP 和 FPS 分别达到 94.26% 和 68 f/s, 优于 Faster-RCNN、YOLOv4 和常规 YOLOv5 等网络, 满足斜拉桥拉索表面缺陷检测精度和实时性要求。

**关键词:** 斜拉桥拉索; 缺陷检测; YOLOv5s 网络; TRANS 模块; 损失函数

中图分类号: TP391

文献标志码: A

王鹏峰, 李运堂, 黄永勇, 等. 基于改进 YOLOv5s 网络的斜拉桥拉索表面缺陷检测 [J]. 光电工程, 2024, 51(5): 240028

Wang P F, Li Y T, Huang Y Y, et al. Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network[J]. Opto-Electron Eng, 2024, 51(5): 240028

## Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network

Wang Pengfeng<sup>1</sup>, Li Yuntang<sup>2\*</sup>, Huang Yongyong<sup>2</sup>, Zhu Wenkai<sup>2</sup>, Lin Jie<sup>2</sup>, Wang Binrui<sup>2</sup>

<sup>1</sup>College of Modern Science and Technology, China Jiliang University, Jinhua, Zhejiang 322002, China;

<sup>2</sup>College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou, Zhejiang 310018, China

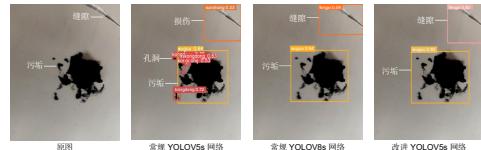
**Abstract:** An improved YOLOv5s network for defects detection for the cable surface of cable-stayed bridge fast and accurately is proposed. This overcomes the problems of low efficiency and poor safety of manual inspection, slow and inaccuracy of existing target detection methods because of the interference of dirt leading to wrong and missed detections. The TRANS module is added to the backbone network of conventional YOLOv5s to obtain more features of a single image and improve defect detection accuracy. Moreover, the CSP module of the neck network is replaced by the GhostBottleneck module and ordinary convolution is replaced by depth-separable convolution to reduce parameters and improve the computational speed of the network. Furthermore, the SIOU loss function is

收稿日期: 2024-01-26; 修回日期: 2024-04-19; 录用日期: 2024-04-24

基金项目: 浙江省基础公益研究计划 (LGF19E050002, LZ23E050002, LZ23E060002); 浙江省属高校基本科研业务费专项资金 (2020YW29)

\*通信作者: 李运堂, yuntangli@cjlu.edu.cn。

版权所有©2024 中国科学院光电技术研究所



used for suppressing the oscillation of the bounding box and improving the calculation accuracy of repeatability between the prediction and the real box, which can increase the model stability. The experiments show that mAP and FPS of improved YOLOv5s network are 94.26% and 68 frames per second, respectively. The performance is better than that of Faster-RCNN, YOLOv4, and conventional YOLOv5, and it can find the surface defect for the cable of the cable-stayed bridge accurately and timely.

**Keywords:** cable-stayed bridge cable; defects detection; YOLOv5s network; TRANS module; loss function

## 1 引言

随着社会经济和交通运输业的快速发展, 大跨度桥梁建造技术不断成熟, 应用日益增多。斜拉桥作为大跨度桥梁的主要形式, 具有造型美观、抗震能力强、跨度大、成本低、施工方便等突出优点, 广泛应用于跨河跨江跨海大桥。作为主要承载部件, 拉索是斜拉桥安全服役的基本保证, 其内部由高强度钢丝和防腐涂层组成, 外部主要由聚乙烯或高密度聚乙烯构成保护层。由于长期直接暴露于自然环境, 日晒风吹雨淋及交变荷载作用极易引起保护层侵蚀变形、开裂、甚至剥落, 导致防护功能失效, 腐蚀介质和潮湿水雾进入拉索内部进而引发钢丝腐蚀断裂<sup>[1-2]</sup>。因此, 必须对拉索进行定期检测, 确保桥梁安全。

由于缺少专用设备, 目前斜拉桥拉索检测大都由人工完成, 工作人员搭乘液压升降台对拉索进行检测, 作业范围受升降高度限制; 或是在承压塔顶安装定滑轮, 工作人员搭乘绞盘机带动的吊篮完成拉索检测; 人工作业劳动强度大, 效率低、成本高、存在安全隐患, 漏检率高<sup>[3]</sup>。随着信息技术的快速发展, 基于视觉技术的斜拉桥拉索表面缺陷检测因速度快、精度高、便于推广和应用, 得到广泛关注。

斜拉桥拉索表面缺陷视觉检测利用拉索爬升装置携带相机收集拉索表面图像, 采用图像拼接、统计推断、卷积网络等方法识别和定位缺陷<sup>[4]</sup>。常规图像处理方面, Ho 等<sup>[5]</sup>结合主成分分析和图像增强, 采用中值滤波和直方图均衡对拉索表面图像进行预处理, 有效降低图像噪声, 提高检测精度。Li 等<sup>[6]</sup>通过尺度不变特征变换实现了具有重叠区域图像的拼接, 获取拉索表面完整图像, 但缺陷检测效率有待提高。

常规图像处理拉索表面缺陷检测精度较低, 容易产生漏检、错检, 而语义分割通过对每个像素设定类别获取完整的缺陷轮廓, 使检测精度大幅提高。赵鹤等<sup>[7]</sup>构建了融合注意力机制的金属带材缺陷分割网络, 将网络分为通道注意力模块的语义路径和位置注意力

模块的旁路路径, 可有效减少信息丢失, 提高检出率, 但计算量大、耗时长。Pan 等<sup>[8]</sup>构建语义分割网络检测污水管道缺陷, 在 UNet 跳跃链接路径增加特征复用和注意力机制, 利用损失函数解决类别不平衡问题, 但检出率易受光照影响。

随着深度学习技术的快速发展, 目标检测在机器视觉领域的应用越来越普遍。相对于常规图像处理和语义分割, 目标检测同时学习图像深浅层特征信息, 检测精度大幅提高<sup>[9]</sup>。赵宏伟等<sup>[10]</sup>提出基于双模态深度学习网络的钢轨表面缺陷检测方法, 将图像深层信息作为网络输入, 显著降低误检率。Hou 等<sup>[11]</sup>利用掩模区域神经网络结合迁移学习识别和定位拉索表面缺陷, 检测精度高, 但检测速度慢。李运堂等<sup>[12]</sup>通过优化先验框尺寸, 主干网络引入空间金字塔池化(spatial pyramid pooling, SPP)模块, 利用 CIoU(complete intersection over union)损失函数等方法改进 YOLOv3 网络实现拉索表面缺陷快速检测, 检测速度快, 但精度易受污垢影响。孙泽强等<sup>[13]</sup>构建了 YOLOv5-CFD 模型检测钢带表面缺陷, 采用聚类分析获得先验框, 在主干网络添加频域通道注意力模块, 检测精度较常规 YOLOv5 提高了 4.2%。Huang 等<sup>[14]</sup>通过多个卷积层和池化层自动识别钢丝绳表面缺陷, 克服了手动提取特征的局限性。张银胜等<sup>[15]</sup>以 MobileNetv3 作为主干特征提取网络, 利用通道注意力机制提取特征, 大幅提高涡轮机表面缺陷检测速度, 并且漏检率低。Qiao 等<sup>[16]</sup>在深度特征聚集分割网络中引入空间通道挤压和激励注意力机制模块进行路面裂缝检测, 方法抗干扰能力强、误检率低。Li 等<sup>[17]</sup>采用特征金字塔(feature pyramid network, FPN)融合不同尺度特征图, 将特征信息映射至多尺度网络实现钢带表面缺陷检测和定位。

针对斜拉桥拉索表面缺陷尺寸差异大、表面污垢和缺陷特征差异性小, 常规 YOLOv5s 网络拉索表面缺陷检测存在漏检、误检、速度慢、精度低等问题。本文改进 YOLOv5s 网络, 在主干网络增加 TRANS

模块, 提高检测精度; 颈部网络利用 GhostBottleneck 替代 CSP (cross stage partial) 模块, 同时利用深度可分离卷积代替普通卷积, 大幅减少网络参数, 提高检测精度和速度; 引入 SIOU (scylla intersection over union) 边界框损失函数精确计算边界框重复度。采用聚氯乙烯管模拟拉索保护套搭建数据集, 对缺陷和污垢进行分类训练得到最终网络参数; 消融实验和对比实验表明: 改进 YOLOv5s 网络缺陷和污垢检测精度和速度显著提高, 满足斜拉桥拉索表面缺陷和污垢自动检测需求。

## 2 YOLOv5s 网络分析

YOLO 为单阶段目标检测网络, 其优势在于在特征提取后直接回归目标位置和类别, 检测速度相对于双阶段网络大幅提高。相对于 YOLO 早期版本, YOLOv5 通过特征融合和多尺度训练, 具有先验框数量多、网络尺寸小、检测速度快等优点, 包括 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 四种模型, 上述模型深度和宽度依次增加, 检测速度却逐

渐降低<sup>[18]</sup>。考虑到拉索表面缺陷检测实时性要求, 选用网络深度和宽度最小、检测速度最快的 YOLOv5s 网络检测拉索表面缺陷。

### 2.1 常规 YOLOv5s 网络

常规 YOLOv5s 网络结构如图 1 所示。包括主干网络、颈部网络和头部网络。主干网络采用 CSPDarknet53 结构, 通过增加 CSP 模块和残差结构, 提高网络效率和精度。颈部网络连接主干网络和头部网络, 进一步处理和筛选主干网络提取的特征, 提高检测精度。头部网络对颈部网络输出的特征进行目标检测和定位, 输出检测框和类别信息。相对于其它 YOLOv5 模型, YOLOv5s 层数和参数最少, 同时将常规 YOLOv5 网络的 Focus 模块替换为 6×6 普通卷积拼接到通道维度中, 有效提高特征提取效率。

主干网络由多个特征提取模块组成, 包括 CBS (ConvBNSiLU) 模块和 CSP 模块。CBS 模块由普通卷积 (Conv)、批量归一化 (batch normalization, BN) 和 SiLU 激活函数组成。CSP 模块将图像特征经两次 CBS 和 CBS+Bottleneck 的输出堆叠, 再经 CBS 提取

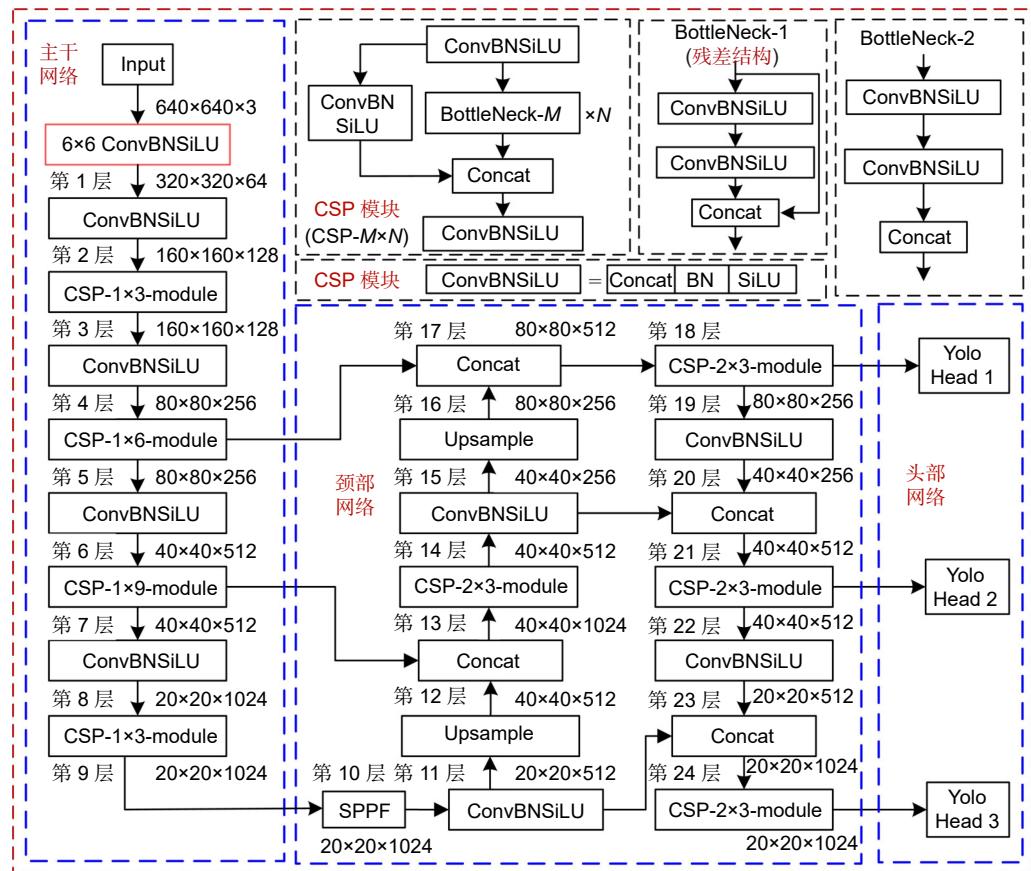


图 1 常规 YOLOv5s 网络结构

Fig. 1 Structure of the conventional YOLOv5s network

更多图像特征。

颈部网络采用快速空间金字塔池化(spatial pyramid pooling fast, SPPF)和CSP模块提取和筛选图像特征。SPPF具有SPP和FPN特性,不改变图像尺寸而高效融合不同尺度特征,增强网络表达能力,获得更加丰富的特征信息,如图2所示。

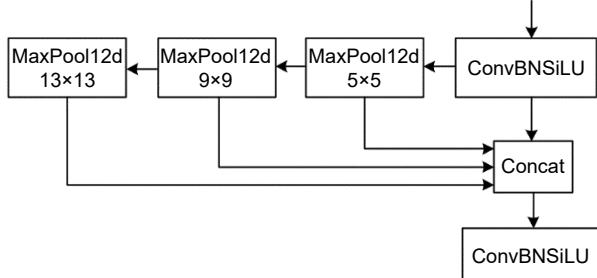


图 2 SPPF 模块

Fig. 2 SPPF module

SPPF利用 $5\times 5$ 、 $9\times 9$ 和 $13\times 13$ 三个卷积核对图像进行最大池化操作,提取图像特征并减少梯度信息重复,增大感受野并获得不同尺度特征。

头部网络利用卷积运算输出置信度、类别预测和坐标位置,同时生成多组不同尺度检测框,提高检测精度。

## 2.2 网络预测

如表1所示,常规YOLOv5s网络共有9种尺寸先验框。

表 1 常规 YOLOv5s 先验框尺寸

Table 1 Prior box size of conventional YOLOv5s

特征图	尺寸	先验框尺寸
特征图1	$80\times 80$	(10, 13), (16, 30), (33, 23)
特征图2	$40\times 40$	(30, 61), (62, 45), (59, 119)
特征图3	$20\times 20$	(116, 90), (156, 198), (373, 326)

YOLOv5s主干网络将输入图像划分为不同尺度特征图,最终以三种尺度进行预测。以 $640\times 640$ 的图像为例,网络采用 $320\times 320\sim 960\times 960$ 之间的随机尺寸开始训练。经过CSP和SPPF后划分为400、1600、6400个网格,每一个网格生成预测框,并判断预测框内是否存在检测对象。特征图依次为 $20\times 20$ 、 $40\times 40$ 、 $80\times 80$ ,分别预测大尺度、中尺度和小尺度目标。

网络预测时首先调整目标先验框中心点,每个先验框有 $5+M$ 个参数。即:先验框中心坐标 $(t_x, t_y)$ 、宽高缩放比 $t_w$ 和 $t_h$ 、置信度conf和类别总数M。

预测框如图3所示, $C_x$ 和 $C_y$ 分别为网格左上角的横坐标和纵坐标, $P_w$ 和 $P_h$ 分别为特征图先验框的宽和高, $b_w$ 和 $b_h$ 分别为调整后预测框的宽和高, $\sigma$ 为激活函数。

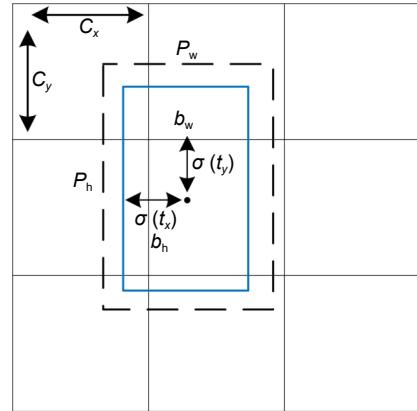


图 3 预测框示意图

Fig. 3 Schematic diagram of the prediction box

$$b_x = (2\sigma(t_x) - 0.5) + C_x, \quad (1)$$

$$b_y = (2\sigma(t_y) - 0.5) + C_y, \quad (2)$$

$$b_w = P_w \cdot (2\sigma(t_w))^2, \quad (3)$$

$$b_h = P_h \cdot (2\sigma(t_h))^2, \quad (4)$$

式中: $(b_x, b_y)$ 为调整后目标预测框中心点坐标。真实目标中心点靠近特征图左上角和右下角时,坐标偏移量取极大值或极小值获得网络预测值,为使预测框中心坐标不超过网格区域,控制预测偏移量取值范围为 $-0.5\sim 1.5$ 。早期YOLO版本未限制预测框宽高比例,可能出现梯度发散,影响训练过程。因此,YOLOv5s网络宽高比取值为0~4。

YOLOv5s网络通过预测框与真实框模板匹配确定预测框内是否包含检测对象, $R_{\max}$ 为 $R_w^{\max}$ 和 $R_h^{\max}$ 的最大值, $R_{\max}$ 小于设定阈值时,表示预测框内存在检测对象。

$$R_{\max} = \max(R_w^{\max}, R_h^{\max}), \quad (5)$$

$$R_w^{\max} = \max(R_w, 1/R_w), \quad (6)$$

$$R_h^{\max} = \max(R_h, 1/R_h), \quad (7)$$

式中: $R_w^{\max}$ 为预测框和真实框在宽度方向的最大差值, $R_h^{\max}$ 为预测框和真实框在高度方向的最大差值。

$$R_w = W_{gt}/W_{at}, \quad (8)$$

$$R_h = h_{gt}/h_{at}, \quad (9)$$

式中: $W_{gt}$ 和 $h_{gt}$ 分别为预测框的宽和高, $W_{at}$ 和 $h_{at}$ 分别为真实框的宽和高。

预测框内存在检测对象时特征层中每个网格可能

生成多个预测框。采用非极大值抑制 (non-maximum suppression, NMS) 剔除网格中同一类别多余预测框, 得到最佳预测框。

$$D_i = \begin{cases} D_i, & IOU(Q, E_i) < N_m \\ 0, & IOU(Q, E_i) \geq N_m \end{cases}, \quad (10)$$

式中:  $N_m$  为非极大值抑制阈值。 $IOU(Q, E_i)$  为目标预测框和其余框的交并比。

$$IOU(Q, E_i) = S_{Q \cap E_i} / S_{Q \cup E_i}, \quad (11)$$

式中:  $Q$  为预测框,  $E_i$  为其余框。

### 2.3 常规 YOLOv5s 网络的不足

斜拉桥拉索表面缺陷形状各异, 尺寸差别大, 并且缺陷和污垢图像特征相似。常规 YOLOv5s 网络针对 COCO 数据集, 该数据集检测类别多且检测对象颜色各异, 与拉索表面缺陷特征相差较大。因此, 常规 YOLOv5s 网络检测拉索表面缺陷极易引起缺陷和污垢混淆, 导致误检或漏检。同时, 常规 YOLOv5s 主干网络多尺度特征学习能力不足, 颈部网络 CSP 模块存在特征冗余, 预测框回归位置不精准、检测精度低、速度慢等问题。因此, 改进常规 YOLOv5s 网

络结构和损失函数, 实现拉索表面缺陷快速准确检测。

## 3 YOLOv5s 网络改进

### 3.1 改进 YOLOv5s 网络结构

为克服常规 YOLOv5s 网络拉索表面缺陷检测不足, 对网络结构进行如下改进:

1) 在主干网络增加 TRANS 模块, 提高模型表征能力, 降低误检率和漏检率。

2) 在颈部网络利用 GhostBottleneck 代替 CSP 模块, 同时利用深度可分离卷积代替普通卷积, 在保证检测精度的同时, 大幅提高检测速度。

改进 YOLOv5s 网络结构如图 4 所示。

#### 3.1.1 TRANS 模块

由于斜拉桥拉索表面缺陷形状多样, 如孔洞、缝隙等小目标缺陷, 常规 YOLOv5s 网络特征提取困难。因此, 在 YOLOv5s 主干网络引入基于 Transformer 的编码器 TRANS 模块<sup>[19]</sup>, 充分利用缺陷图像全局信息, 提高小目标缺陷特征提取能力, 降低误检率和漏检率, 提高缺陷检测精度。TRANS 模块如图 5 所示。

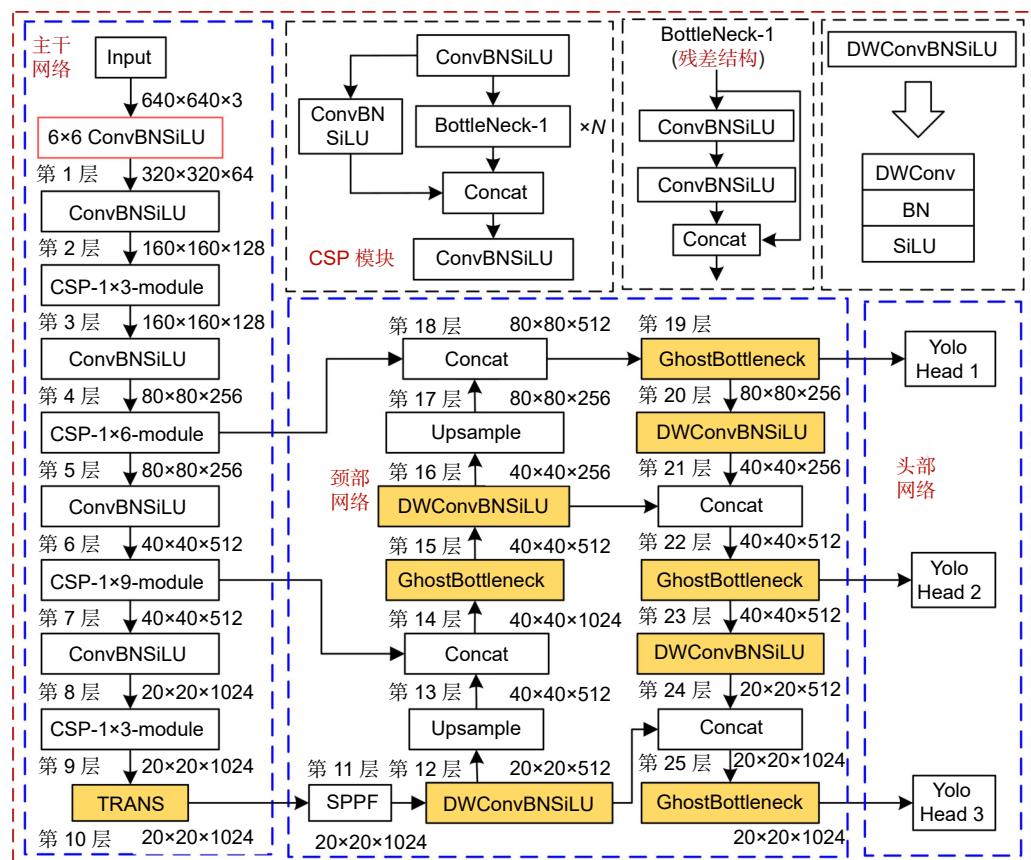


图 4 改进 YOLOv5s 网络结构

Fig. 4 Structure of the improved YOLOv5s network

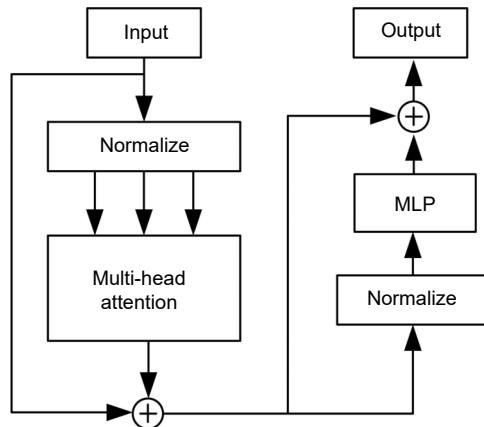


图 5 TRANS 模块

Fig. 5 TRANS module

TRANS 模块将归一化(normalize)和多头注意力机制(multi-head attention, MHA)处理后的特征图与原特征图堆叠后输出, 该输出再与经过归一化和多层次感知机(multilayer perceptron, MLP)操作的结果进行堆叠。

TRANS 模块可以更好地捕捉缺陷图像的全局信息, 并提供丰富的缺陷上下文特征。在特征提取阶段, TRANS 模块收集更大邻域特征信息, 有助于学习更多特征, 提高检测精度。但 TRANS 模块处于网络层较浅位置时, 容易触发边界回归, 导致上下文特征信息丢失。因此, 将 TRANS 模块添加在 YOLOv5s 主干网络末端, 此处特征图分辨率低, 从而有效抑制信息丢失, 同时降低模型存储空间和计算量, 更适用拉索表面缺陷快速检测。

TRANS 模块引入了 MHA, 如图 6 所示, MHA 将输入特征图分割成多个区域, 并在每个区域内进行线性运算和注意力机制操作, 获取关键特征信息。MHA 通过相同的注意力机制学习不同缺陷特征, 再将不同特征堆叠后进行变换, 获得最终输出。相对于传统注意力机制, MHA 有效防止将注意力过度集中于自身位置导致错检, 并且提取更多的特征信息, 降低漏检率。

### 3.1.2 GhostBottleneck 模块

常规 YOLOv5s 颈部网络的 CSP 模块将输入特征图分为两条路径分别进行卷积计算, 利用跳跃链接堆叠后输出。但过多卷积计算导致网络参数显著增加, 计算速度降低, 并且容易产生大量冗余特征。为减少网络参数, 提高检测速度, 满足拉索表面缺陷检测实时性要求, 借鉴 GhostNet 思想, 选用步长为 1 的 GhostBottleneck 模块代替 YOLOv5s 网络颈部的 CSP

模块<sup>[20]</sup>。GhostBottleneck 模块通过 Ghost 操作, 将输入特征图分为主要特征图和辅助特征图两部分。主要特征图用于提取主要特征信息, 辅助特征图则提供额外信息。因此, GhostBottleneck 模块在保持高性能的同时参数量更少, 计算效率更高。

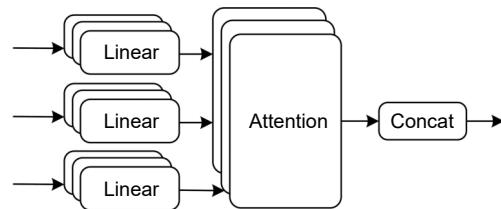


图 6 多头注意力机制

Fig. 6 Multi-head attention

GhostBottleneck 模块如图 7 所示, 将输入分成两条路径, 一条路径经过两个 Ghost 稀疏连接后与另外一条路径进行堆叠, 从而提高网络泛化能力。

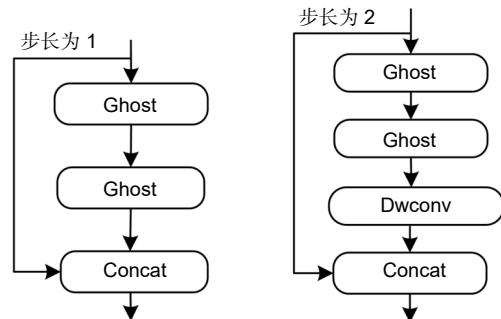


图 7 GhostBottleneck 模块

Fig. 7 GhostBottleneck module

Ghost 结构如图 8 所示, 输入特征图经过普通卷积和线性变换后输出, 同时保持特征图尺寸不变, 并减小模型参数和计算量。

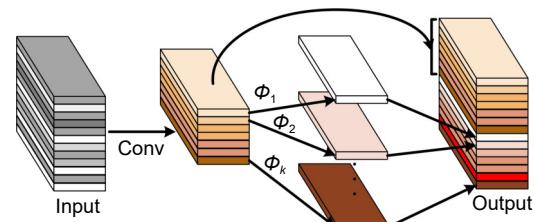


图 8 Ghost 结构

Fig. 8 Ghost structure

### 3.1.3 深度可分离卷积

深度可分离卷积(Dwconv)将卷积拆分为逐深度卷积和  $1 \times 1$  逐点卷积, 能够大幅减小参数量、降低内存需求。以  $80 \times 80 \times 3$  图像为例, 深度可分离卷积参数量约为普通卷积的  $1/3$ , 计算效率显著提高。利用深度可分离卷积代替颈部网络的普通卷积, 进一步提高检测速度。

### 3.2 损失函数设计

YOLOv5s 网络的损失函数由分类损失、定位损失和置信度损失组成。考虑斜拉桥拉索表面缺陷特征复杂, 常规 YOLOv5s 网络的 CIOU 容易受小目标缺陷干扰, 对于缝隙、孔洞等形状不规则的小目标缺陷, CIOU 容易引起误检。此外, CIOU 需手动设计评价指标。SIOU 结合了目标框的位置和大小信息, 对小目标缺陷的真实框和预测框重叠度计算更准确, 适合不同形状的缺陷检测。因此, 为解决真实框与预测框不匹配问题, 提高网络收敛速度和稳定性, 引入了 SIOU 作为预测框定位损失函数。

SIOU 损失函数包括角度损失、距离损失、形状损失和 IOU 损失四部分。

角度损失如图 9 所示。

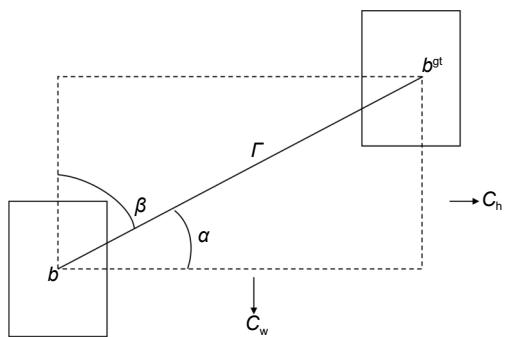


图 9 角度损失  
Fig. 9 Angle loss

$$\Lambda = \cos(2\arcsin(C_h/\Gamma) - \pi/4), \quad (12)$$

$$C_h = \max(b_{cy}^{gt}, b_{cy}) - \min(b_{cy}^{gt}, b_{cy}), \quad (13)$$

$$\Gamma = \sqrt{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2}, \quad (14)$$

式中:  $\Lambda$  为角度损失,  $(b_{cx}^{gt}, b_{cy}^{gt})$  和  $(b_{cx}, b_{cy})$  分别为真实框和预测框中心点坐标,  $\Gamma$  和  $C_h$  分别为预测框与真实框中心点距离和高度差。

距离损失如图 10 所示。

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma\rho_t}), \quad (15)$$

$$\rho_x = \left( \frac{b_{cx}^{gt} - b_{cx}}{C_w} \right)^2, \quad (16)$$

$$\rho_y = \left( \frac{b_{cy}^{gt} - b_{cy}}{C_h} \right)^2, \quad (17)$$

$$\gamma = 2 - \Lambda, \quad (18)$$

式中:  $\Delta$  为距离损失,  $C_w$  为预测框与真实框中心点的宽度差。

形状损失为

$$\mathcal{Q} = (1 - e^{-w_w})^n + (1 - e^{-w_h})^n, \quad (19)$$

$$w_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})}, \quad (20)$$

$$w_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})}, \quad (21)$$

式中:  $w$  和  $h$  分别为预测框的宽高,  $w^{gt}$  和  $h^{gt}$  分别为真实框的宽高,  $n$  的取值范围为 2~6。

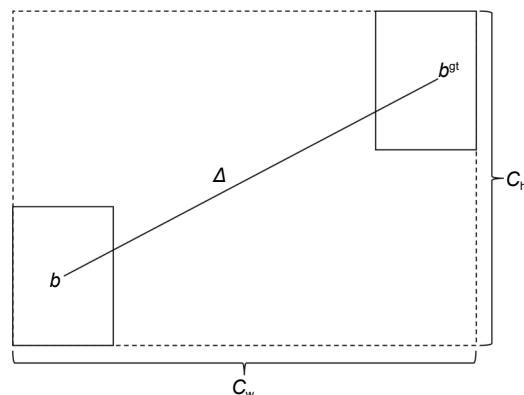


图 10 距离损失  
Fig. 10 Distance loss

SIOU 损失其计算公式为

$$L_{siou} = 1 - IOU + (\Delta + \mathcal{Q})/2. \quad (22)$$

### 3.3 评价指标

选取目标检测主流评价指标检验改进 YOLOv5s 网络检测效果, 包括精确度 (P)、召回率 (R)、平均精度 (AP)、多类别平均精度 (mAP) 和帧数 (FPS)<sup>[21]</sup>。

1) 单个类别精确度

$$P = \frac{TP}{TP + FP}, \quad (23)$$

式中:  $P$  为模型正确预测缺陷类别数与所有缺陷数的比值,  $TP$  为正确预测缺陷数,  $FP$  为错误预测缺陷数。

2) 单个类别召回率

$$R = \frac{TP}{TP + FN}, \quad (24)$$

式中:  $FN$  为错误预测缺陷类别数。

3) 平均精度

$$AP = f(P, R), \quad (25)$$

式中:  $AP$  指由坐标轴和精确度曲线所包围区域面积。 $AP$  值越高, 单个类别检测性能越好。

4) 多类别平均精度

$$mAP = \frac{1}{M} \sum_{i=1}^M AP_i, \quad (26)$$

式中:  $M$  表示检测对象类别数,  $mAP$  反应网络整体检测精度。

5) FPS 为每秒处理图像数量, 反映检测速度。

## 4 缺陷检测实验

### 4.1 拉索表面缺陷数据集搭建

由于现场采集斜拉桥拉索表面图像危险性高, 而开放数据集较少, 因此选择与拉索表面材料相近的 PVC (polyvinyl chloride) 管模拟拉索保护套。在 PVC 管材上构造缝隙、损伤、孔洞和污垢, 如图 11 所示。

利用爬升装置搭载 4 个工业相机同时拍摄拉索表面图像, 四路图像之间存在 20% 左右的重叠, 通过发射机将图像信息无线传输到接收机。采用数据采集卡将四路图像合并成一幅图像传入计算机, 考虑运动速度、视频帧率和图像之间的重复度, 间隔 20 帧保存一张图像。

### 4.2 数据集扩充与标注

为避免数据样本少导致训练过拟合, 通过变换拍



图 11 拉索表面缺陷数据采集

Fig. 11 Data collection of cable surface defects

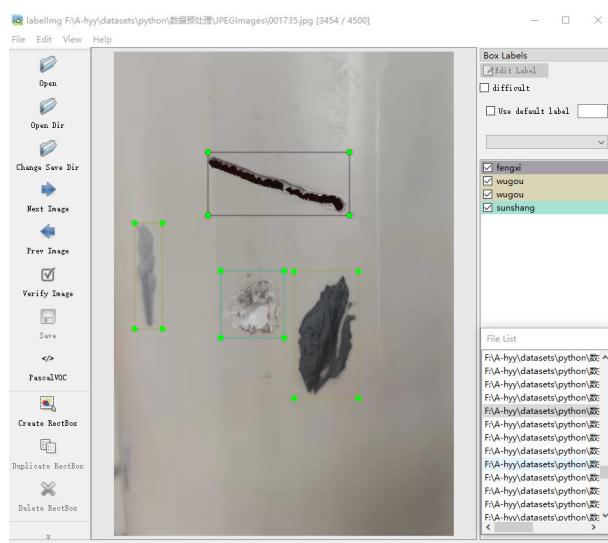


图 13 标注实例

Fig. 13 Annotation instance

摄角度和相对位置获取 2000 张清晰可用的拉索表面缺陷和污垢图像, 利用 Mosaic 扩充数据集。如图 12 所示, 选择四张图像随机进行缩放、裁剪和拼接等操作, 大幅提高单张图像语义信息。扩充后数据集包含 4500 张缺陷及污垢图像。其中, 训练集 3600 张, 验证集和测试集均为 450 张。

将数据集中的检测目标分为孔洞、缝隙、损伤和污垢, 利用 LabelImg 标注图像中缺陷和污垢, 输出含有缺陷和污垢位置和类型的 xml 文件, 标注实例如图 13 所示。

### 4.3 网络训练

改进 YOLOv5s 网络利用 GPU 进行训练, 学习率和学习率衰减系数分别为 0.01 和 0.0005, 采用 SGD 优化器, 学习率动量为 0.937, batch\_size 为 8, 训练 500 个 epoch。从图 14 中的损失曲线可以看出, 前 100 次迭代中, 训练集损失值与验证集损失值均下降

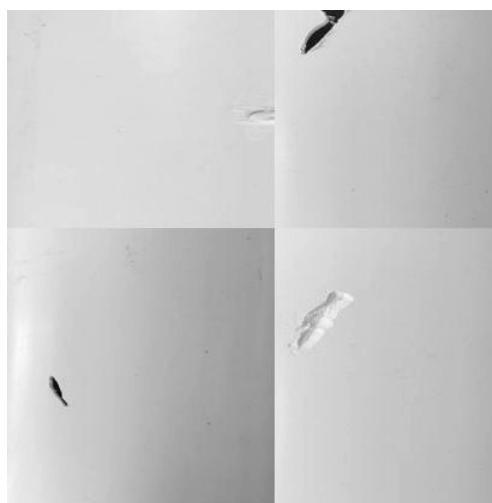


图 12 Mosaic 数据扩充

Fig. 12 Mosaic data augmentation

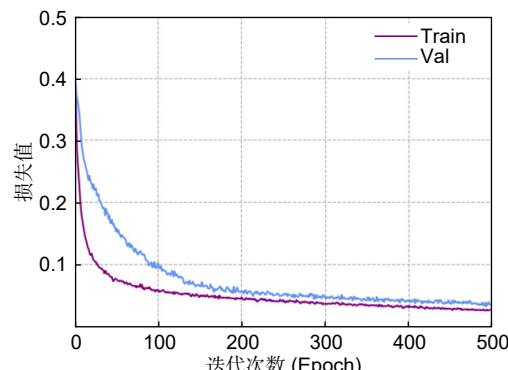


图 14 损失值变化曲线

Fig. 14 Loss value variation curve

迅速, 迭代 300 次后逐渐趋于稳定, 最终训练集损失值收敛于 0.028 左右, 验证集损失值收敛于 0.035 左右, 表明网络已经取得了较好的训练结果。

#### 4.4 消融对比实验

为验证改进方法有效性, 进行消融对比实验, 如表 2 所示。其中,  $a$  表示孔洞,  $b$  表示缝隙,  $c$  表示损伤,  $d$  表示污垢; 方法 1: 在常规 YOLOv5s 主干网络末端增加 TRANS 模块; 方法 2: 以方法 1 为基础, 在颈部网络利用 GhostBottleneck 模块代替 CSP 模块; 方法 3: 以方法 2 为基础, 在颈部网络利用深度可分离卷积代替普通卷积; 方法 4: 在方法 3 的基础上引入 SIOU 损失函数。

结果表明, 方法 1 相对于常规 YOLOv5s 网络, 四类目标的 AP 均大幅提高, 表明增加 TRANS 模块充分地融合了不同尺寸的缺陷特征, 有效提高了检测精度; 方法 2 和方法 3 的 FPS 持续增加, 表明利用 GhostBottleneck 模块和深度可分离卷积分别替换 CSP 模块和普通卷积能减少网络参数量, 大幅提高检测速度; 方法 4 的 mAP 最高, 表明采用 SIOU 作为预测框损失函数降低了边界框振荡, 提高了网络鲁棒性。

表 2 消融对比实验  
Table 2 Ablation comparative experiment

算法	AP /%				mAP /%	FPS
	$a$	$b$	$c$	$d$		
常规 YOLOv5s	90.42	89.08	83.77	91.57	87.71	56
方法 1	91.92	92.54	94.01	96.13	93.65	51
方法 2	94.09	91.81	90.32	95.62	92.96	64
方法 3	93.20	92.23	91.26	95.83	93.13	68
方法 4	<b>95.11</b>	<b>91.29</b>	<b>93.42</b>	<b>97.22</b>	<b>94.26</b>	<b>68</b>

#### 4.5 对比实验

选用常规 YOLOv5s 网络, 常规 YOLOv8s 网络和改进 YOLOv5s 网络在测试集进行检测, 结果如图 15 所示。

图 15 第一张原图中, 改进 YOLOv5s 网络检测结果置信度高于常规 YOLOv5s 网络和常规 YOLOv8s 网络; 图 15 第二张原图中, 常规 YOLOv5s 网络将缝隙错检为损伤, 同时存在缝隙漏检, 常规 YOLOv8s 网络检测小目标效果较差, 存在缝隙漏检情况, 改进 YOLOv5s 网络准确检测缝隙、孔洞缺陷; 图 15 第

三张原图中, 常规 YOLOv5s 网络将污垢错检为孔洞, 并且存在检测目标重叠, 常规 YOLOv8s 网络和改进 YOLOv5s 网络均能检测出污垢、缝隙缺陷, 但常规 YOLOv8s 网络检测缝隙缺陷精度低于改进 YOLOv5s 网络, 表明改进 YOLOv5s 网络增强了多尺度特征学习能力和抗干扰能力, 提高了检测精度。

#### 4.6 不同网络检测对比实验

选取目标检测领域常用的 Faster RCNN、文献 [12] 网络 (改进 YOLOv3 网络)、YOLOv4 网络、常规 YOLOv5s 网络、常规 YOLOv8s 网络和改进 YOLOv5s 网络进行对比实验, 并采用评价指标 mAP 和 FPS 定量分析不同网络检测结果, 如表 3 所示。

可以看出, 改进 YOLOv5s 网络的检测精度和检测速度均优于其它网络, mAP 和 FPS 分别达到了 94.26% 和 68 f/s, 相对于 Faster R-CNN 网络分别提高了 3.69% 和 65 f/s, 相对于文献 [12] 网络 (改进 YOLOv3 网络) 分别提高了 6.37% 和 52 f/s, 相对于 YOLOv4 网络分别提高了 4.89%、48 f/s, 相对于常规 YOLOv5s 网络和常规 YOLOv8s 网络分别提高了 6.55%、9 f/s 和 1.88%、17 f/s。

为进一步验证改进 YOLOv5s 网络的检测性能, 在通用目标检测数据集 VOC 2007 (训练集 2501 张, 验证集 2510 张, 测试集 4952 张) 中进行对比实验, 实验结果如表 4 所示。

可以看出, 改进 YOLOv5s 网络检测精度最高, 速度最快, mAP 和 FPS 分别达到了 78.21% 和 71 f/s, 均优于其它对比网络。

## 5 结 论

通过改进 YOLOv5s 网络解决斜拉桥拉索表面缺陷检测易出现错检、漏检、精度低、速度慢等问题。为提高检测精度, 在主干网络末端增加 TRANS 模块提取更多特征; 利用 GhostBottleneck 模块和深度可分离卷积分别替换颈部网络的 CSP 模块和普通卷积, 减少模型参数和计算成本, 获得轻量级网络; 选用 SIOU 作为边界框损失函数, 更好地计算边界框重复度, 提高网络收敛速度。利用 PVC 管材模拟拉索表面构建缺陷和污垢数据集。实验结果表明, 改进 YOLOv5s 网络满足斜拉桥拉索表面缺陷检测精度和速度要求。

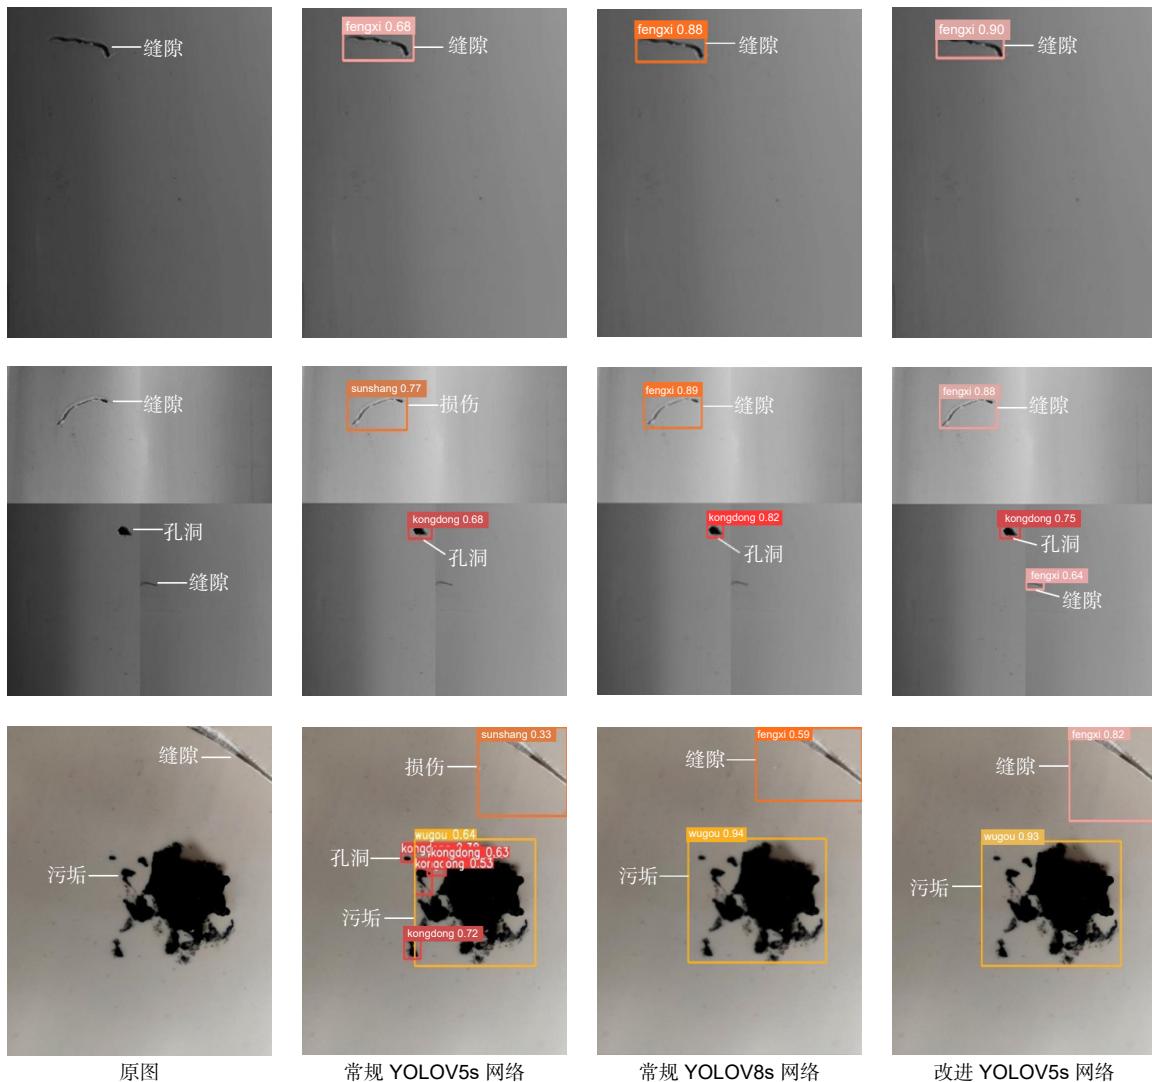


图 15 不同网络检测结果对比

Fig. 15 Comparison of different network detection results

表 3 不同网络在拉索表面缺陷数据集的检测结果

Table 3 Detection results of different networks on the surface defect dataset of the cable

网络	mAP /%	FPS
Faster R-CNN	90.57	3
文献[12]	87.89	16
YOLOv4	89.37	20
常规YOLOv5s	87.71	59
常规YOLOv8s	92.38	51
<b>改进YOLOv5s</b>	<b>94.26</b>	<b>68</b>

**利益冲突:**所有作者声明无利益冲突

## 参考文献

[1] Yan D H, Guo X. Influence of damage of stay cables on

表 4 不同网络在 VOC 2007 数据集检测结果

Table 4 Detection results of different networks on VOC 2007 dataset

网络	mAP /%	FPS
Faster R-CNN	76.38	4
文献[12]	71.91	21
YOLOv4	73.12	26
常规YOLOv5s	72.57	63
常规YOLOv8s	76.82	57
<b>改进YOLOv5s</b>	<b>78.21</b>	<b>71</b>

system reliability of in-service cable-stayed bridges[J]. *J Central South Univ (Sci Technol)*, 2020, 51(1): 213–220.

颜东煌, 郭鑫. 斜拉索损伤对在役斜拉桥体系可靠度的影响[J]. *中南大学学报(自然科学版)*, 2020, 51(1): 213–220.

- [2] Xu F Y, Dai S Y, Jiang Q S, et al. Developing a climbing robot for repairing cables of cable-stayed bridges[J]. *Autom Constr*, 2021, 129: 103807.

- [3] Li S B, Yang J, Wang Z, et al. Review of development and application of defect detection technology[J]. *Acta Autom Sin*, 2020, **46**(11): 2319–2336.  
李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. *自动化学报*, 2020, **46**(11): 2319–2336.
- [4] Zheng Z L, Yuan X Q, Huang H H, et al. Mechanical design of a cable climbing robot for inspection on a cable-stayed bridge[C]//*Proceedings of the 13th World Congress on Intelligent Control and Automation*, 2018: 1680–1684. <https://doi.org/10.1109/WCICA.2018.8630709>.
- [5] Ho H N, Kim K D, Park Y S, et al. An efficient image-based damage detection for cable surface in cable-stayed bridges[J]. *NDT E Int*, 2013, **58**: 18–23.
- [6] Li X K, Gao C, Guo Y C, et al. Cable surface damage detection in cable-stayed bridges using optical techniques and image mosaicking[J]. *Opt Laser Technol*, 2019, **110**: 36–43.
- [7] Zhao H, Yang X H, Yang Q, et al. Metal defect image segmentation algorithm combined with attention mechanism[J]. *J Optoelectron Laser*, 2021, **32**(4): 403–408.  
赵鹤, 杨晓洪, 杨奇, 等. 融合注意力机制的金属缺陷图像分割方法[J]. *光电子·激光*, 2021, **32**(4): 403–408.
- [8] Pan G, Zheng Y X, Guo S, et al. Automatic sewer pipe defect semantic segmentation based on improved U-Net[J]. *Autom Constr*, 2020, **119**: 103383.
- [9] Xiao Y Z, Tian Z Q, Yu J C, et al. A review of object detection based on deep learning[J]. *Multimed Tools Appl*, 2020, **79**(33–34): 23729–23791.
- [10] Zhao H W, Zheng J J, Zhao X X, et al. Rail surface defect method based on bimodal-modal deep learning[J]. *Comput Eng Appl*, 2023, **59**(7): 285–293.  
赵宏伟, 郑嘉俊, 赵鑫欣, 等. 基于双模态深度学习的钢轨表面缺陷检测方法[J]. *计算机工程与应用*, 2023, **59**(7): 285–293.
- [11] Hou S T, Dong B, Wang H C, et al. Inspection of surface defects on stay cables using a robot and transfer learning[J]. *Autom Constr*, 2020, **119**: 103382.
- [12] Li Y T, Xie M M, Wang P F, et al. Defects inspection method for cable surface of cable-stayed bridge based on improved YOLOv3 algorithm[J]. *Chin J Sens Actuators*, 2021, **34**(11): 1509–1517.  
李运堂, 谢梦鸣, 王鹏峰, 等. 基于改进YOLOv3算法的斜拉桥拉索表面缺陷检测方法[J]. *传感技术学报*, 2021, **34**(11): 1509–1517.
- [13] Sun Z Q, Chen B C, Cui X B, et al. Strip steel surface defect detection by YOLOv5 algorithm fusing frequency domain attention mechanism and decoupled head[J]. *J Comput Appl*, 2023, **43**(1): 242–249.  
孙泽强, 陈炳才, 崔晓博, 等. 融合频域注意力机制和解耦头的YOLOv5带钢表面缺陷检测[J]. *计算机应用*, 2023, **43**(1): 242–249.
- [14] Huang X Y, Liu Z L, Zhang X Y, et al. Surface damage detection for steel wire ropes using deep learning and computer vision techniques[J]. *Measurement*, 2020, **161**: 107843.
- [15] Zhang Y S, Yang Y L, Ji R, et al. Surface defect detection of wind turbine based on YOLOv5s[J]. *J Electron Meas Instrum*, 2023, **37**(1): 40–49.  
张银胜, 杨宇龙, 吉茹, 等. 改进YOLOv5s的风力涡轮机表面缺陷检测[J]. *电子测量与仪器学报*, 2023, **37**(1): 40–49.
- [16] Qiao W T, Liu Q W, Wu X G, et al. Automatic pixel-level pavement crack recognition using a deep feature aggregation segmentation network with a scSE attention mechanism module[J]. *Sensors*, 2021, **21**(9): 2902.
- [17] Li K Y, Wang X F, Ji L J. Application of multi-scale feature fusion and deep learning in detection of steel strip surface defect[C]//*Proceedings of 2019 International Conference on Artificial Intelligence and Advanced Manufacturing*, 2019: 656–661. <https://doi.org/10.1109/AIAM48774.2019.00136>.
- [18] Fan H D, Zhu D Q, Li Y H. An improved yolov5 marine biological object detection algorithm[C]//*Proceedings of the 2nd International Conference on Artificial Intelligence and Computer Engineering*, 2021: 29–34. <https://doi.org/10.1109/ICAICE54393.2021.00014>.
- [19] Strudel R, Garcia R, Laptev I, et al. Segmenter: transformer for semantic segmentation[C]//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*, 2021: 7262–7272. <https://doi.org/10.1109/ICCV48922.2021.00717>.
- [20] Zhao Z Y, Yang X X, Zhou Y C, et al. Real-time detection of particleboard surface defects based on improved YOLOv5 target detection[J]. *Sci Rep*, 2021, **11**(1): 21777.
- [21] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, **39**(4): 640–651.

## 作者简介



王鹏峰(1983-), 男, 工学硕士, 讲师, 主要从事自动化装置的结构设计、相关参数优化及控制系统的研究。

E-mail: wangpf23@cjlu.edu.cn



【通信作者】李运堂(1976-), 男, 工学博士, 中国计量大学教授, 硕士生导师, 主要从事拉索检测维护机器人、无人机电力线巡检方面的研究。

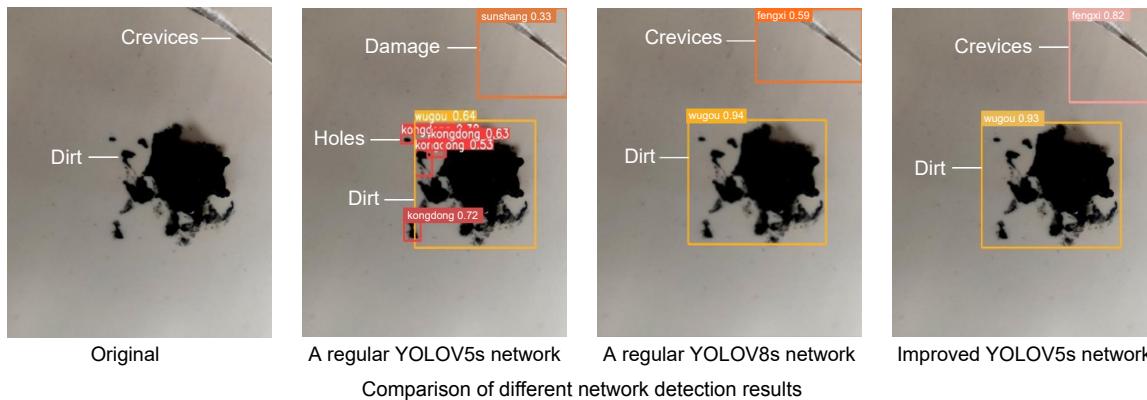
E-mail: yuntangli@cjlu.edu.cn



扫描二维码, 获取PDF全文

# Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network

Wang Pengfeng<sup>1</sup>, Li Yuntang<sup>2\*</sup>, Huang Yongyong<sup>2</sup>, Zhu Wenkai<sup>2</sup>, Lin Jie<sup>2</sup>, Wang Binrui<sup>2</sup>



Comparison of different network detection results

**Overview:** In recent years, the construction technology of large-span bridges has developed rapidly and its application has increased. As the main form of large-span bridges, the cable-stayed bridge has outstanding advantages such as beautiful appearance, strong seismic resistance, long span distance, low cost, and convenient construction. Therefore, it is widely used in bridges for crossing rivers or seas. As the main load-bearing component, the cable guarantees cable-stayed bridges being serviced safely. The interior of the cable is composed of high-strength steel wires and anti-corrosion coatings while the exterior is mainly protected by polyethylene or high-density polyethylene. Due to long-term exposure to the natural environment and affected by sunlight, wind, rain, and other factors, the protective layer of the cable is extremely easy to be erosion, deformation, cracking, and even peeling, which leads to the failure of the protective function. Furthermore, corrosion media and humid water mist entering the interior of the cable will cause steel wire corrosion and fracture. Therefore, regular cable detection is necessary to ensure bridge safety. Due to the low efficiency, high cost, and poor safety of manual detection of cable surface defects in cable-stayed bridges, existing target detection methods have low accuracy and slow speed, and are easily affected by cable surface dirt interference, resulting in false or missed detections. Therefore, an improved YOLOv5s network is proposed to achieve fast and accurate detection of cable surface defects. Add a TRANS module to the backbone network to obtain more features from a single image and improve defect detection accuracy. In the neck network, GhostBottleneck is used instead of the CSP module, and depthwise separable convolution is used instead of regular convolution to ensure detection accuracy while effectively reducing network parameters and significantly improving detection speed. Introducing the SIOU loss function to solve the problem of mismatch between the real and predicted boxes of small target defects, and improving the convergence speed and stability of the network. Using polyvinyl chloride pipes to simulate cable protection sleeves, constructing a dataset for experiments. The experimental results show that the *mAP* and *FPS* of the improved YOLOv5s network reach 94.26% and 68 frames per second, respectively, which are superior to Faster RCNN, YOLOv4, conventional YOLOv5, and other networks, meeting the requirements of surface defect detection accuracy and real-time performance for cable-stayed bridges.

Wang P F, Li Y T, Huang Y Y, et al. Defects detection for cable surface of cable-stayed bridge based on improved YOLOv5s network[J]. *Opto-Electron Eng*, 2024, 51(5): 240028; DOI: [10.12086/oee.2024.240028](https://doi.org/10.12086/oee.2024.240028)

Foundation item: Zhejiang Province Basic Public Welfare Research Program (LGF19E050002, LZ23E050002, LZ23E060002), and Special Funds for Basic Scientific Research Business Expenses of Zhejiang Provincial Universities (2020YW29)

<sup>1</sup>College of Modern Science and Technology, China Jiliang University, Jinhua, Zhejiang 322002, China; <sup>2</sup>College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou, Zhejiang 310018, China

\* E-mail: [yuntangli@cjlu.edu.cn](mailto:yuntangli@cjlu.edu.cn)