

基于改进 YOLOv7 的线束缺陷检测研究^{*}

袁海兵 赵凤胜 杨奕洋 吴俊
(湖北汽车工业学院机械工程学院 十堰 442002)

摘要:针对目前线束端子压接缺陷检测过程中存在检测效率低、误检率高等问题,提出一种基于改进 YOLOv7 的线束缺陷检测方法。为提高算法的检测精度,在 YOLOv7 主干网络中添加归一化注意力模块(NAM),加强对检测目标的定位和识别;在颈部构建多尺度的集中特征金字塔网络(CFP),以捕捉不同尺度下的目标信息,加深图像深层特征的提取;使用 SIoU Loss 替换 CIoU Loss 优化训练模型,在加快模型收敛的同时提高预测框的回归精度。实验结果表明,改进后的 YOLOv7 网络模型准确率达 95.8%,召回率达 94.5%,均值平均精度达 97.6%,与原模型相比分别提高了 5.0%、4.8%和 3.3%,模型大小 90.5 MB,检测时间为 48 ms,有效提高了模型的检测精度。最后,使用 PyQt5 开源框架设计了线束端子压接缺陷检测系统,实现了端子压接缺陷检测的自动化和可视化,提高了缺陷检测效率,可以满足生产企业的需要。

关键词:线束端子压接;缺陷检测;YOLOv7;注意力机制;集中特征金字塔

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research on wire harness defect detection based on improved YOLOv7

Yuan Haibing Zhao Fengsheng Yang Yiyang Wu Jun
(School of Mechanical Engineering, Hubei University of Automotive Technology, Shiyan 442002, China)

Abstract: Aiming at the problems of low detection efficiency and high false detection rate in the current process of crimping defects of wire harness terminals, a wire harness defect detection method based on improved YOLOv7 is proposed. To improve the detection accuracy of the algorithm, the NAM attention mechanism is added to the YOLOv7 backbone network to strengthen the localization and recognition of detection targets. A multi-scale concentrated feature pyramid (CFP) network was constructed at the neck to capture the target information at different scales and deepen the extraction of deep features of the image. Use SIoU Loss to replace CIoU Loss to optimize the training model, which improves the regression accuracy of the prediction box while accelerating the model convergence. The experimental results show that the improved YOLOv7 network model has an accuracy rate of 95.8%, a recall rate of 94.5%, and an average accuracy of 97.6%, which is 5.0%, 4.8% and 3.3% higher than the original model, respectively, with a model size of 90.5 MB and a detection time of 48 ms, which effectively improves the detection accuracy of the model. Finally, the wire harness terminal crimping defect detection system is designed using the PyQt5 open-source framework, which realizes the automation and visualization of terminal crimping defect detection, improves the defect detection efficiency, and can meet the needs of production enterprises.

Keywords: crimping of wiring harness terminals; defect detection; YOLOv7; attention mechanisms; centralized feature pyramid (CFP)

收稿日期:2023-08-29

^{*} 基金项目:教育部产学合作协同育人项目(201902016046,201902118034)、湖北省科技厅企业创新发展项目(2021BAB018)、十堰市科学技术研究指导项目(16Y97)资助

0 引言

线束在电子设备中起着连接和传输信号的作用,其质量对设备的性能和可靠性至关重要,而端子作为线束生产过程中的重要连接组件,其压接质量严重影响线束的物理性能与电气性能^[1]。在线束端子压接过程中,需要对压接后的线束端子进行缺陷检测,保障线束端子的压接质量。由于线束端子较小且种类较多,目前企业针对其缺陷的检测主要依靠显微放大装置进行人工抽检,不仅检测效率低,而且检测结果受主观因素影响较大,无法保证产品的质量。

随着机器视觉技术的快速发展,利用视觉检测技术实现线束端子压接缺陷检测已成为重点研究方向。袁彬涂等^[2]针对线束端子压接后的外观缺陷,提出一种基于定位基准拟合算法以及缺陷特征计算方法的图像检测方法,对线束压接外观图像进行检测,但需人工进行算法参数调优。张相胜等^[3]针对端子压接后线芯外露、端子变形等问题,设计了一套基于机器视觉的线束压接缺陷检测系统,利用图像处理技术完成对线束关键部位特征的检测,但检测时间过长。侯守明等^[4]针对传统图像处理方法自动提取线束端子截面边界轮廓不准确的问题,提出一种基于偏微分方程和 Canny 算子的边缘检测模型。上述传统视觉检测方法多采用模板匹配的方法进行缺陷检测,对光源要求较高,检测对象单一,检测效率低,误检率高,无法满足多种线束端子的检测需求。

随着 Faster R-CNN^[5]、SSD^[6]、YOLO^[7] 等深度学习目标检测算法的快速发展,许多学者已将目标检测算法用于线束检测领域并加以改进,取得了不错的效果。朱世松等^[8]根据端子线芯显微成像呈密集且不规则排列的特性,提出一种改进 EfficientDet 的线束端子显微图像线芯检测算法用于线芯计数,最终在自制数据集上得到了 96.2% 的检测精度。丁成波等^[9]针对线束与端子压接过程中出现压接不到位、线芯外露等质量问题,提出一种传统视觉与深度学习相结合的方法实现线束端子外观缺陷智能检测,识别准确率达 99.33%。王泽一^[10]针对线束端子压接质量检测过程中存在检测准确率低、漏检率较高等问题,分别使用浅层卷积神经网络与 Mobile Net 网络对线束端子压接质量数据集进行模型的训练与预测,最终 Mobile Net 网络表现更好,准确率达 94.12%。

由于线束端子种类较多,端子压接缺陷较小,基于传统机器视觉的检测方法对检测环境要求较高,检测效率较低,误检率高,通用性差,无法满足实际检测需求。为满足线束端子压接缺陷检测需求,本文以 YOLOv7 算法为基础,首先构建了图像采集平台,然后采集线束端子压接缺陷图像制作数据集,最后结合注意力机制、特征金字塔网络以及损失函数对算法进行改进,实现对缺陷区域的特征提取、目标定位与分类,提高线束端子压接缺陷检测的效率和精度。

1 数据集制作

在线束端子压接过程中,通常使用端子压接机将线束线芯和外皮分别与金属端子的线芯包筒和绝缘皮包筒压接在一起,由于送线位置偏差或线束剥皮后线芯分叉等原因,极易导致线芯压接位置错误、线芯外露等缺陷,严重影响线束连接的牢固性和电流传输的可靠性。线束端子正确压接如图 1 所示,其中,线芯包筒用于压接线芯;绝缘皮包筒用于压接线束外皮。



图 1 线束端子正确压接图

1.1 图像采集平台构建

对线束端子压接区域进行外观缺陷检测时,需要获取高质量的端子压接图像,为此,采用维视智造公司研发的 MV-VS1200 S 创新实验平台用于采集线束端子压接图像。图像采集平台如图 2 所示,主要包括 CCD 工业相机、工业镜头、环形光源、测试台架以及计算机。

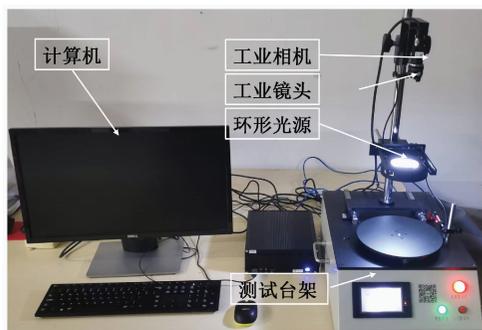


图 2 图像采集平台

1.2 制作数据集

根据常见的线束端子压接缺陷类型,将其划分为外皮浅打(shallow,绝缘皮包筒压接了线芯)、外皮深打(deep,线芯包筒压接了线束外皮)、线芯外露(leak,线芯包筒线芯外露)、包角断裂(crack,绝缘皮包筒断裂)和无线芯(wireless,线芯包筒未压接线芯)5种缺陷类型。为了保证数据集内图像的多样性,在数据集制作过程中,采用不同

型号端子压接4种不同颜色电子线,通过图像采集平台采集包括正确压接(true)在内的6种类型图片共计520张,对采集的图片使用Labelimg软件进行标注,并使用不同的标签名将其分类。6种类型端子压接图像如图3所示。

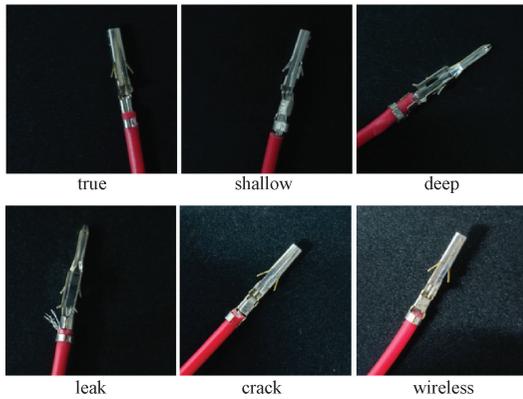


图3 6种类型端子压接图像

由于采集到的缺陷图像数据量有限,为了使最终的模型在复杂场景能够有良好表现,对采集的图片进行平移变换、翻转变换、噪声扰动、对比度变换以及尺度变换5种数据增强方法扩充数据集,每张图片数据增强5次,共获得3120张照片。

通过Python脚本文件将3120张照片及对应标签按照8:1:1的比例划分为训练集、验证集和测试集,获得训练集2496张照片、验证集312张照片、测试集312张照片。其中,训练集用于模型的训练,验证集用于调整模型的超参数,而测试集则是用来评估模型的性能。

2 YOLOv7 算法原理与改进

YOLOv7^[11]是一种典型的一阶段目标检测算法,其提供了YOLOv7、YOLOv7x、YOLOv7-tiny等7种大小不同的模型,针对线束端子压接缺陷检测任务的特点以及目前检测过程中存在的问题,本文选用YOLOv7为基础模型。YOLOv7主要分为4个部分,分别是输入端(Input)、主干网络(Backbone)、网络颈部(Neck)以及输出预测(Prediction)模块。Input模块会对训练集图像进行预处理,以便能够满足主干网络的输入大小要求。Backbone模块由若干CBS模块、ELAN模块以及MP模块组成,主要用于提取特征信息。Neck模块由SPPCSPC模块以及路径聚合网络(path aggregation network, PANet)结构构成^[12],其通过自底向上和自顶向下两条路径双向融合的方式进一步增强骨干特征的代表能力。Prediction模块对Neck模块处理后的3个特征层进行结果预测并输出预测结果,其输出大小与输入图片大小相关,输出维度与需要识别的目标种类数量相关。

YOLOv7虽然在普通场景下取得了较好的检测效果,但将其直接应用于线束端子压接缺陷检测中仍存在检

测精度低的问题,为此本文在YOLOv7的基础上进行改进,首先,在主干网络中添加归一化注意力模块(normalization-based attention module, NAM),让网络专注于有效信息,帮助模型更加精确地定位和识别;其次,在颈部构建多尺度的集中特征金字塔网络(centralized feature pyramid, CFP),以捕捉不同尺度下的目标信息,减少冗余计算,加深对图像深层特征的提取;最后,使用SIoU替换CIoU计算坐标损失,加快预测框的收敛速度,提高模型回归精度,改进后的YOLOv7网络结构如图4所示。

2.1 NAM注意力机制

由于线束端子压接缺陷目标在图像中所占比例较小,经过卷积层不断提取特征后,容易丢失目标信息,为此,在YOLOv7主干网络中引入了一种高效轻量级的注意力机制,即基于注意力模块。NAM^[13]注意力机制是在卷积块注意力模块(convolutional block attention module, CBAM)注意力机制的基础上重新设计通道和空间注意力模块,在每个网络块的末端嵌入一个NAM模块,通过利用训练模型权重的方差度量来突出显著特征,使网络在更大的范围内注意到缺陷目标,更加准确地定位和识别^[14]。

在通道注意力模块中, NAM通过批归一化(batch normalization, BN)中的缩放因子测量每个通道的方差,用于体现权重的重要性^[15],计算公式为:

$$B_{out} = BN(B_{in}) = \gamma \frac{B_{in} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (1)$$

式中: B_{in} 为输入特征; B_{out} 为输出特征; μ_B 为均值; σ_B^2 为标准差; ϵ 为误差; γ 、 β 分别为可训练的放射变化参数。

通道注意力模块结构如图5所示,其中 F_i 表示输入特征, M_c 表示输出特征。 γ 是每个通道的缩放因子,权值为:

$$\omega_i = \frac{\gamma_i}{\sum_{j=0} \gamma_j} \quad (2)$$

NAM还将BN的缩放因子应用于空间维度,来衡量空间特征的重要性,空间注意力模块结构如图6所示,其中 M_s 代表输出特征, λ 为缩放因子,权值为:

$$\omega_\lambda = \frac{\lambda_i}{\sum_{j=0} \lambda_j} \quad (3)$$

2.2 集中特征金字塔网络

线束端子压接缺陷检测任务不仅需要缺陷目标进行定位还需要对检测到的目标进行分类,这就要求输入检测层的特征图需要包含丰富的细节特征和语义特征。由于线束端子为金属制品,在不同光照情况的影响下,易导致YOLOv7网络对缺陷目标特征的提取不够充分,影响最终检测结果。为此,在YOLOv7颈部网络构建多尺度的CFP网络^[16],以捕捉不同尺度下的目标信息,加强网络对线束端子压接图像中缺陷目标的特征提取能力。

CFP网络主要由显式视觉中心模块(explicit visual center, EVC)和全局中心化调节网络(global centralized

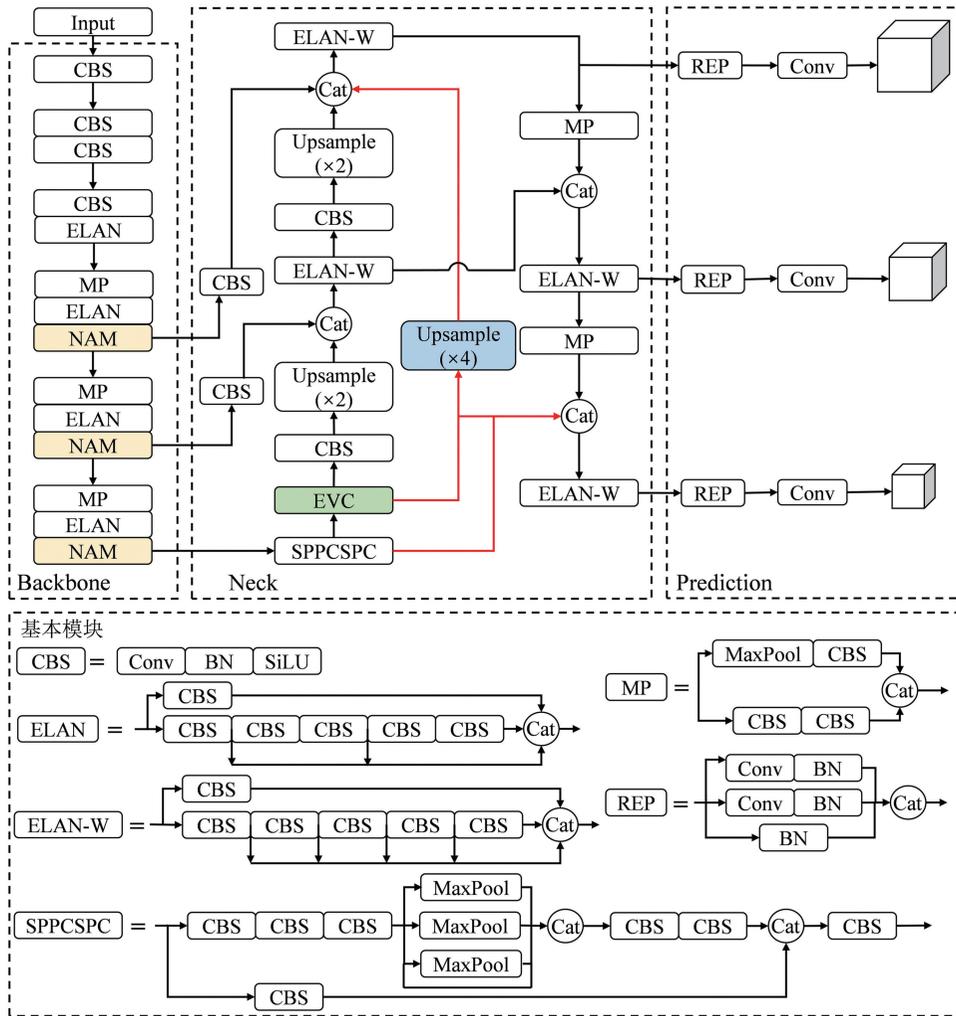


图4 改进后的YOLOv7网络结构

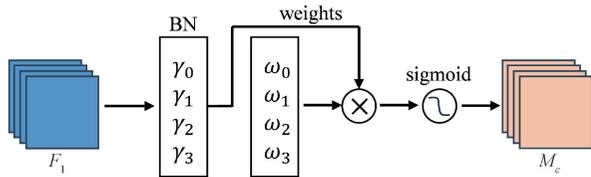


图5 通道注意力模块结构

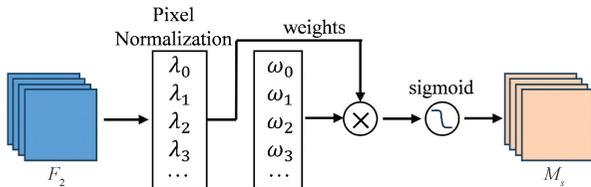


图6 空间注意力模块结构

regulatory, GCR) 组成, 其中 EVC 包括轻量级 MLP (multi-layer perception) 架构和可学习视觉中心机制 (learnable visual center, LVC) 两部分^[17], EVC 模块结构如图 7 所示。

CFP 网络在接收到主干部分输出的特征图后, 通过 stem 模块对特征图进行特征平滑, 然后使用轻量级 MLP 架构来捕获顶层特征的全局长距离依赖性, 并使用 LVC 来聚合输入图像的局部角落区域特征, 两个模块的结果特征映射沿着通道维度连接在一起, 作为 EVC 的输出传递到下游的识别模型中, 而 GCR 则将在深层中获得的特征上采样到与低层特征相同的空间尺度, 然后沿信道维度进行连接, 使模型获得更全面的端子压接图像中缺陷目标的特征信息, EVC 计算公式如下:

$$X = \text{cat}(\text{MLP}(X_{in}); \text{LVC}(X_{in})) \quad (4)$$

$$X_{in} = \sigma(\text{BN}(\text{Conv}_{7 \times 7}(X_4))) \quad (5)$$

式中: X 为 EVC 的输出; $\text{MLP}(X_{in})$ 为轻量级 MLP 的输出特征; $\text{LVC}(X_{in})$ 为可学习视觉中心机制的输出特征; X_{in} 为 Stem 模块的输出。

2.3 损失函数改进

YOLOv7 在进行迭代计算时使用损失函数来表征预测框与真实框之间的差异程度, 通过不断更新权重值, 损失函数不断减小。在 YOLOv7 检测网络中, 损失函数由

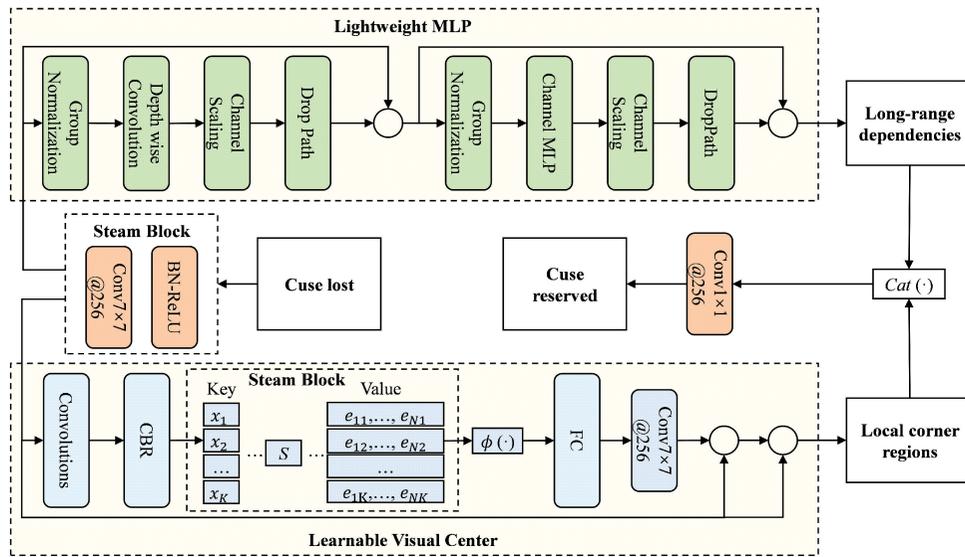


图7 EVC 模块结构

坐标损失、目标置信度损失和分类损失 3 部分构成,其使用 CIoU 作为坐标损失函数,同时采用 BCEWithLogitsLoss(带 log 的二值交叉熵损失)函数计算目标置信度损失和分类损失。

CIoU 损失函数不仅考虑了重叠区域、中心点距离和长宽比 3 个方面对边框损失的影响,还解决了两个检测框中心点重合时仍为边界框提供移动方向的问题^[18],但是该方法并没有考虑预测框与目标框之间方向的匹配性,还存在着收敛速度较慢以及计算损失不稳定的特点。

针对以上问题,本文采用更高效的 SIoU^[19]来替换原模型中的 CIoU 计算坐标损失。SIoU 损失函数由角度损失、距离损失、形状损失和 IoU 损失 4 部分组成,其参数图如图 8 所示,计算公式为:

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (6)$$

式中:IoU 为真实框和预测框交并比; Δ 表示考虑了角度成本后重新定义的距离成本,代表了预测框与真实框的中心点距离; Ω 表示形状成本。

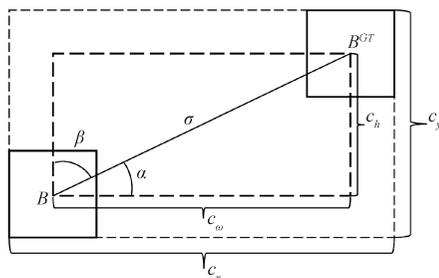


图8 SIoU 损失函数参数图

SIoU 通过引入所需回归之间的向量角度,重新定义了惩罚指标,使得模型的训练速度与推理能力都比之前有

所提高。因此,本文将 SIoU 作为 YOLOv7 网络的坐标损失函数。

3 实验结果与分析

3.1 模型训练

本文模型训练和测试均在 windows10 操作系统的高性能工作站上运行,其配置为 Inter 3.10 GHz 8 核 CPU,运行内存为 32 GB,一张 NVIDIA T4 GPU,显存为 32 G,Python 版本为 3.7.0,torch 版本为 1.7.1,torch vision 版本为 0.8.2,CUDA 版本为 11.1。

由于采集的图像分辨率较高,设置输入图片的大小为 640×640 ,模型训练时对图像进行缩放处理。在训练过程中,分别使用余弦退火法调整学习效率和随机梯度下降优化器优化参数,批尺寸(batch size)设置为 8,每次训练 200 个世代。

3.2 模型的评价指标

为了检测改进算法的效果与效率,本文选取预测框与目标框的 IoU 阈值大于 0.5 作为判定目标检测的标准,使用准确率(precision, P)、召回率(recall, R)和平均精度均值(mean average precision, mAP)作为模型的评价指标,用于衡量检测精度。P 表示正确预测的样本占有所有检测出目标的比例,R 代表正确预测样本占有所有目标的比例,mAP 表示不同类别的平均精度(AP)的平均值,AP 为 P-R 曲线与坐标轴围成的面积,其计算公式为:

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$AP = \int_0^1 P(R) dR \quad (9)$$

$$mAP = \frac{\sum(AP)}{n} \quad (10)$$

式中: TP 表示被正确检出的目标数; FP 表示被错误检出的目标数; FN 表示没有被正确检出的目标数; n 为目标检测的总类别数。

3.3 损失函数对比

为验证不同损失函数对模型性能的影响,在保证其他参数不变的情况下,改变损失函数进行对比实验,改进前后损失函数对比如图9所示。从图9可以看出,随着模型迭代次数的不断增加,目标的坐标损失不断下降,SIoU损失函数均值更小,最低损失值可收敛到0.025左右,且无过拟合现象,模型收敛效果更好。

3.4 消融实验分析

为了验证本文改进点对YOLOv7算法的影响,在保

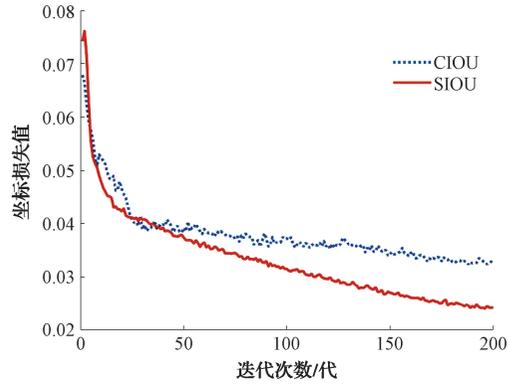


图9 改进前后损失函数对比

证数据集、训练的配置参数、平台框架相同的基础上,对改进点进行了8组消融实验,实验结果对比如表1所示。

表1 消融实验结果对比

模型	NAM	CFP	SIoU	$P/\%$	$R/\%$	mAP/ $\%$	检测时间/ms
YOLOv7				90.8	89.7	94.3	43
YOLOv7_A	✓			91.4	90.5	95.2	44
YOLOv7_B		✓		93.3	90.1	95.7	46
YOLOv7_C			✓	91.3	93.2	95.3	40
YOLOv7_AB	✓	✓		94.1	91.9	96.3	49
YOLOv7_AC	✓		✓	91.7	93.0	96.2	44
YOLOv7_BC		✓	✓	94.8	92.7	96.6	46
YOLOv7_ABC	✓	✓	✓	95.8	94.5	97.6	48

“✓”表示在YOLOv7中添加相应模块,实验结果表明,对YOLOv7基础网络添加相应模块后均能够对最终的结果产生正向优化,其中构建CFP集中特征金字塔网络对于识别准确率的贡献相对较为明显。YOLOv7原算法的准确率只有90.8%,mAP只有94.3%,在引入NAM注意力机制模块后,帮助模型更加精确地定位和识别,较原模型相比准确率提高0.6%,mAP提高0.9%;在颈部构建多尺度的集中特征金字塔网络后,网络通过额外的特征融合路径进一步提取浅层信息,使模型对线束端子压接的检测也更加准确,较原模型相比准确率提高2.5%,mAP提升1.4%;引入SIoU损失函数后,利用边界框回归所需的向量角度重新定义损失函数,提高了模型边界框的定位精度,较原模型相比准确率提高0.5%,mAP提高1.0%,而召回率提高了3.5%,检测时间提高3ms;在上述3组已改进过的任何一个模型中引入新的改进方法,准确率与mAP均得到提升,且检测时间相差较少,说明采用的改进方法耦合性较好;最后将上述3种改进方法同时应用至YOLOv7模型中,较原模型相比准确率提高5.0%,R提高了4.8%,mAP提高了3.3%。改进前后YOLOv7算法训练过程中mAP对比如图10所示,改进

后的网络模型整体检测精度明显增加。

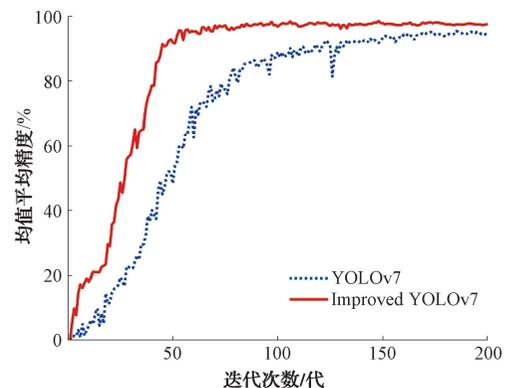


图10 训练过程中mAP对比

3.5 与其他目标检测算法进行性能对比

为验证本文算法对线束端子压接缺陷检测的有效性,在相同数据集下,将本文算法与Faster R-CNN、SSD、YOLOv4、YOLOv5l目标检测算法进行对比,同时使用准确率、召回率、mAP、模型大小以及检测时间作为评价指标,检测结果如表2所示。

表 2 不同算法检测结果

模型	模型大小/MB	P/%	R/%	mAP/%	检测时间/ms
Faster R-CNN	108.6	85.2	83.4	89.8	132
SSD	100.3	83.9	82.1	88.6	72
YOLOv4	244.0	87.7	86.6	91.5	61
YOLOv5l	89.7	88.6	87.6	93.7	41
YOLOv7	74.9	90.8	89.7	94.3	43
改进后的 YOLOv7	90.5	95.8	94.5	97.6	48

由实验结果可知,在保证配置环境及初始训练参数一致的情况下,改进后的 YOLOv7 模型准确率、召回率和检测精度都是最高的,分别可达到 95.8%、94.5% 和 97.6%。相比 Faster R-CNN、SSD 和 YOLOv4,改进后的 YOLOv7 具有更小的模型尺寸和更快的检测速度,并且在准确率上分别领先 10.6%、11.9% 和 8.1%,在均值平均精度上分别领先 7.8%、9.0% 和 6.1%;虽然改进后的 YOLOv7 在模型大小与检测速率上与 YOLOv5l 有较小差距,但在准确率和检测精度上分别有 7.2% 和 3.9% 的提升。由于在网络中添加了

注意力机制并构建了集中特征金字塔网络,增加了部分计算量,导致改进后的 YOLOv7 模型大小有所增加,但准确率提升了 5.0%,召回率提升了 4.8%,平均精度提升了 3.3%,检测时间为 48 ms,满足实际生产现场 100 ms 的检测时间要求。

上述对比数据表明,本文改进的 YOLOv7 算法在线束端子压接缺陷检测上,具有最优的检测精度和较高的检测效率,YOLOv5l 与改进前后 YOLOv7 算法的实际检测结果如图 11~13 所示,改进后的 YOLOv7 模型检测精度明显提升。

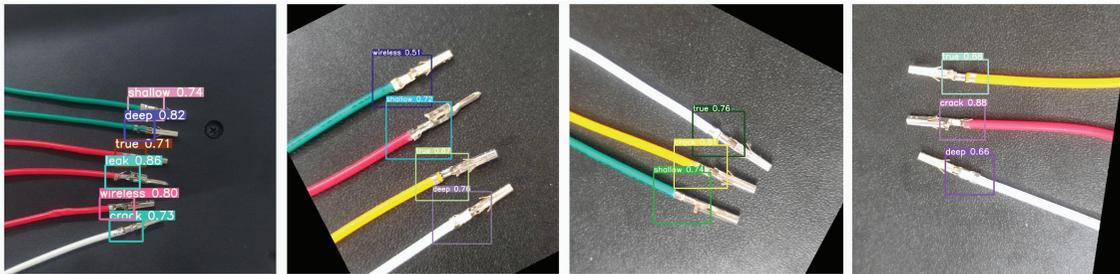


图 11 YOLOv5l 算法检测结果

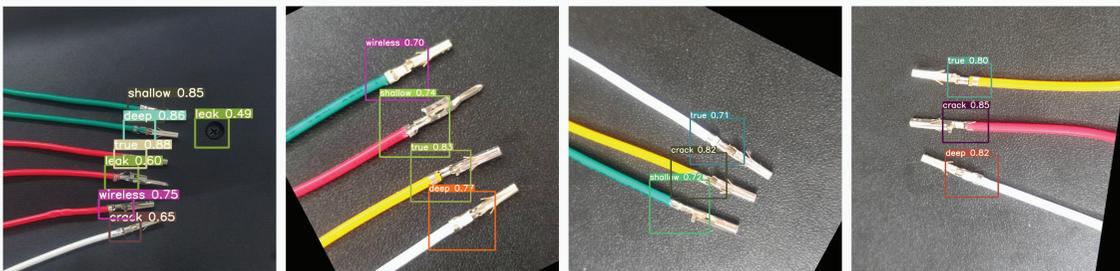


图 12 YOLOv7 算法检测结果

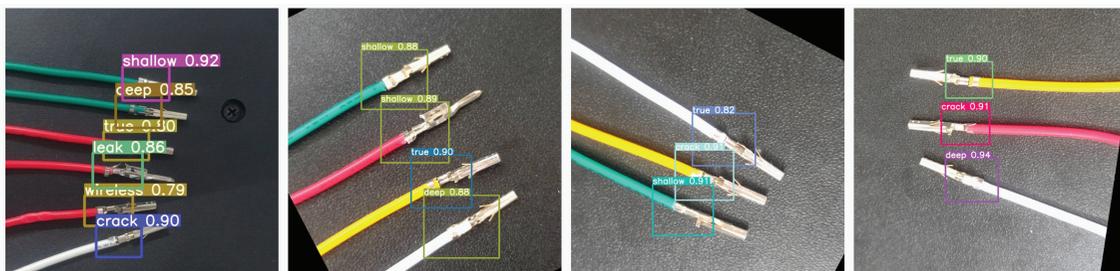


图 13 改进后 YOLOv7 算法检测结果

3.6 线束端子压接缺陷检测系统

本文使用 PyQt5 工具整合线束端子压接缺陷检测模型的权重文件,实现对输入图片的目标识别,其中,使用 QT Designer 完成 GUI 界面的布局设计,再通过 PyUIC 将设计完成的 UI 文件转换为 Python 文件。界面功能包括模型选择、初始化模型、图片检测、打开相机、开始检测、检测结果显示区以及检测信息显示区。系统检测结果如图 14 所示。

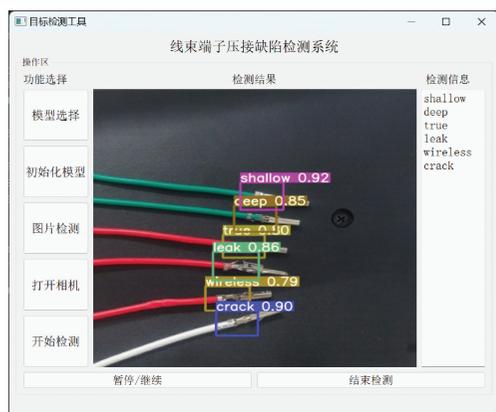


图 14 系统检测结果

4 结论

针对目前线束端子压接缺陷检测过程中出现误检、漏检、检测效率低等问题,本文提出一种改进的 YOLOv7 检测模型。通过在主干网络中添加 NAM 注意力机制模块,提升网络的定位能力;在颈部构建多尺度的 CFP 集中特征金字塔网络,以捕捉不同尺度下的目标信息,在不增加信息损耗的同时快速进行多尺度融合;将回归损失函数替换为 SIoU 进行网络训练,加快模型收敛速度,提升检测与定位精度,实现对端子压接缺陷的精准定位和识别。实验结果表明,改进后的算法在自制的线束端子压接数据集上的准确率提高了 5.0%,均值平均精度提高了 3.3%,在增加较小的检测速度与模型量的同时获得了更高的检测精度,与其他主流目标检测算法对比得出,改进后的 YOLOv7 算法具有更高的准确率和检测精度。最后,使用 PyQt5 框架开发了图形化界面显示检测结果,系统设计较为完善,兼容性较好,满足线束生产企业的实时检测要求。

在后续工作中,由于改进后的 YOLOv7 算法对硬件设备要求较高,在实际的工业应用中增加了成本,需在不损失检测精度和效率的情况下,对模型进行轻量化等操作,缩减模型大小,降低使用成本。

参考文献

[1] 张良安,刘同鑫,谢胜龙,等. 基于机器视觉的改进线束导线排序检测系统设计[J]. 包装工程, 2023,

44(11):268-276.

- [2] 袁彬淦,钟铭恩,倪晶鑫. 线束端子压接后外观缺陷的视觉检测算法研究[J]. 系统仿真学报, 2022, 34(5):1152-1159.
- [3] 张相胜,焦鹏,潘丰. 基于机器视觉的汽车线束压接缺陷检测系统[J]. 仪表技术与传感器, 2020(3): 73-77.
- [4] 侯守明,王阳,唐琪博,等. 一种基于偏微分方程和 Canny 算子的图像分割方法[J]. 山西大学学报(自然科学版), 2017,40(4):676-682.
- [5] 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.
- [6] LIU W, ANGUÉLOV D, ERHAN D, et al. SSD: Single shot multibox detector [M]. LEIBE B, MATAS J, SEBE N, et al. Computer Vision-ECCV 2016. Lecture Notes in Computer Science. Cham: Springer, 2016, 9905: 21-37.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 779-788.
- [8] 朱世松,孙秀帅,赵理山,等. 基于改进 EfficientDet 的线束端子线芯检测算法[J]. 激光与光电子学进展, 2022,59(18):297-305.
- [9] 丁成波,刘蜜,石锦成,等. 基于深度学习的线束端子外观缺陷检测技术研究[J]. 电线电缆, 2023(2): 54-58.
- [10] 王泽一. 基于机器视觉的线束自动检测系统[D]. 武汉纺织大学, 2022:26-33.
- [11] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 7464-7475.
- [12] 石欣,卢灏,秦鹏杰,等. 一种远距离行人小目标检测方法[J]. 仪器仪表学报, 2022,43(5):136-146.
- [13] LIU Y, SHAO Z, TENG Y, et al. NAM: Normalization-based Attention Module [J]. <https://arxiv.org/abs/2111.12419>.
- [14] 陈建瑜,邹春龙,王生怀,等. 改进 YOLOv5 的路面缺

- 陷快速检测方法研究[J]. 电子测量技术, 2023, 46(10):129-135.
- [15] 陈娟,李燕,阚希,等. 基于 EfficientNet 的轻量化行人检测算法[J]. 国外电子测量技术, 2023, 42(6):1-9.
- [16] QUAN Y, ZHANG D, ZHANG L Y, et al. Centralized feature pyramid for object detection[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2023.
- [17] CAO Z, MEI F F, ZHANG D S, et al. Recognition and detection of persimmon in a natural environment based on an improved YOLOv5 model [J]. Electronics, 2023, 12(4):785.
- [18] 赵梓杉,桑海峰. 基于改进的 YOLOv5 的交通锥标检测系统[J]. 电子测量与仪器学报, 2023, 37(2):56-64.
- [19] GEVORGYAN Z. SiU Loss: More powerful

learning for bounding box regression[J]. Computer Science, 2022, arXiv: 2205.12740.

作者简介

袁海兵,教授,硕士生导师,主要研究方向为汽车零部件测量与控制。

E-mail:yuanhb_jx@huat.edu.cn

赵凤胜(通信作者),硕士研究生,主要研究方向为机器视觉与缺陷检测。

E-mail:202111040@huat.edu.cn

杨奕洋,硕士研究生,主要研究方向为机器视觉与缺陷检测。

E-mail:983859806@qq.com

吴俊,硕士研究生,主要研究方向为机器视觉与缺陷检测。

E-mail:1025407946@qq.com