

基于弱光增强与 YOLO 算法的锯链缺陷检测方法<sup>\*</sup>张福豹<sup>1</sup> 吴 婷<sup>1</sup> 赵春峰<sup>2</sup> 魏贤良<sup>2</sup> 刘苏芬<sup>1</sup>

(1.南通大学机械工程学院 南通 226019; 2.硕与硕(江苏)智能科技有限公司 南通 226499)

**摘要:** 在基于机器视觉的锯链缺陷实时检测过程中,油污、粉尘等因素影响图像亮度和质量,导致目标检测网络的特征提取能力下降。为保证复杂环境下锯链缺陷检测的准确率,本文设计了一种结合弱光增强和 YOLOv3 算法的锯链自动化缺陷检测方法。首先使用 RRDNet 网络自适应增强锯链图像亮度,恢复图像暗区的细节特征;然后采用改进 YOLOv3 算法对锯链零件进行缺陷检测,增加 FPN 结构特征输出图层,利用 K-means 聚类算法对先验框参数重新聚类,并引入 GIoU 损失函数来提高小目标的缺陷检测精度。最后搭建一套锯链缺陷在线检测系统,对所提方法进行验证。实验结果表明,该方法能够显著提高弱光环境下的锯链图像照度、恢复图像细节,改进 YOLOv3 算法的 mAP 值为 92.88%,相比原始 YOLOv3 提高 14%,最终系统整体的漏检率降低到 3.2%,过检率也降低到 9.1%。所提出的方法可实现弱光场景下锯链缺陷的在线检测,并且对多种缺陷有着较高的检测精度。

**关键词:** 锯链;弱光增强;YOLOv3;缺陷检测

**中图分类号:** TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.99

Saw chain defect detection system based on low-light  
enhancement and YOLO algorithmZhang Fubao<sup>1</sup> Wu Ting<sup>1</sup> Zhao Chunfeng<sup>2</sup> Wei Xianliang<sup>2</sup> Liu Susu<sup>1</sup>

(1. School of Mechanical Engineering, Nantong University, Nantong 226019, China;

2. Master and Master (Jiangsu) Intelligent Technology Co., Ltd., Nantong 226499, China)

**Abstract:** In real-time detection of saw chain defects based on machine vision, factors like oil contamination and dust impact image brightness and quality, leading to a decrease in the feature extraction capability of the object detection network. In this paper, an automated saw chain defect detection method that combines low-light enhancement and the YOLOv3 algorithm is proposed to ensure the accuracy of saw chain defect detection in complex environments. In the system, the RRDNet network is used to adaptively enhance the brightness of the saw chain image and restore the detailed features in the dark areas of the image. The improved YOLOv3 algorithm is used for defect detection. FPN structure is added with a feature output layer, the a priori bounding box parameters are re-clustered using the K-means clustering algorithm, and the GIoU loss function is introduced to improve the object defect detection accuracy. Experimental results demonstrate that this approach significantly improve image illumination and recover image details. The mAP value of the improved YOLOv3 algorithm is 92.88%, which is a 14% improvement over the original YOLOv3. The overall leakage rate of the system eventually reduces to 3.2%, and the over-detection rate also reduces to 9.1%. The method proposed in this paper enables online detection of saw chain defects in low-light scenarios and exhibits high detection accuracy for various defects.

**Keywords:** saw chain; low light enhancement; YOLOv3; defect detection

## 0 引言

油锯是林业木料采集的重要工具,锯链作为油锯的关键装配件直接关乎油锯的性能<sup>[1-2]</sup>。在锯链装机长时间

生产过程中,由于现场环境复杂、机器磨损等因素的影响,使得锯链零件产生破损、混料等多类缺陷。人工检测成本高且效率低下。随着生产自动化水平的提高,使用复杂机械生产装配的需求大幅增加,基于机器视觉的缺陷检测方

法被广泛应用。然而视觉检测系统在长时间的检测过程中,会受到油污、粉尘等环境因素的干扰,从而产生大批量低光照数据集。弱光情况下,采集的图像局部特征模糊,模糊特征与零件的缺陷易混淆,直接进行检测会使模型准确率和可靠性降低,现实工业场景下的锯链缺陷检测仍面临着诸多严峻挑战。因此,研究一种弱光环境下的锯链缺陷检测系统对提高锯链生产效率有着重要意义。

近年来,以 Fast R-CNN<sup>[3]</sup>、Faster R-CNN<sup>[4]</sup>为代表的两阶段检测算法和以 YOLO<sup>[5]</sup>、SSD<sup>[6]</sup>为代表的一阶段检测算法被广泛应用。其中,一阶段目标检测算法具有更快的检测速度,满足实际检测效率的要求。马晨凯等<sup>[7]</sup>采用 YOLOv3 目标检测算法设计了陶瓷缺陷检测系统,提高了缺陷检测的精度和速度。李维刚等<sup>[8]</sup>通过改进 YOLOv3 算法的网络结构,采用 K-means++ 算法重新聚类先验框参数,实现了对带钢表面缺陷的精确识别。现有的缺陷检测通常是在光照良好的情况下开展,而实际的工业检测环境常伴随着高噪声、环境条件的变化,噪声和照度的变化可能会掩盖缺陷特征,导致误检或漏检,影响目标检测算法应用时的准确性。因此,缺陷检测算法需要具有一定的泛化能力和自适应能力,减少因环境变化带来的检测性能下降。如何在视觉系统光源变暗的情况下仍保持缺陷识别精度不受影响成了关键。

为了克服上述问题,通常对目标进行缺陷检测之前对图像进行弱光增强预处理<sup>[9]</sup>。增强方法主要分成两种。第一种是使用传统图像处理的方法进行图像增强,Wang 等<sup>[10]</sup>采用小波变换对图像分量进行重构的方式,实现低照度图像自适应增强。Tian 等<sup>[11]</sup>通过双边滤波将图像分解成高低频两域的方式来抑制噪声和粉尘。这些方法能够恢复暗光图像,但是它们更加注重对比度和亮度提升,这使噪声也同时被放大。随着深度学习的发展,另一种基于数据驱动的弱光增强方法被广泛研究。Hu 等<sup>[12]</sup>提出了一种弱光增强缺陷检测算法,融合了弱光增强块和 SE-FP 模块,并成功应用于细罐表面缺陷检测。Hui 等<sup>[13]</sup>针对现有弱光图像增强在细节方面的局限性,提出基于深度学习的 DELLIE 算法。上述这些算法虽然能够有效对暗度图像进行增强,但是这些数据驱动的方法高度依赖数据集,这使得图像恢复过程变得繁琐,并且这些方法仅针对低照度的图像,无法解决实际工业环境中时照度变化情况下图像的自适应调整。

针对弱光环境下锯链高效率、自动化、高精度的在线检测需求,本文提出了一种锯链缺陷检测方法。重点对弱光锯链图像处理与缺陷检测方面进行深入研究。首先利用三支卷积网络(robust retinex decomposition network, RRDNet)<sup>[14]</sup>对照度变低的锯链图像进行预处理,使弱光情况下的锯链图像照度增强。其次,使用前期研究的锯链自适应分割算法<sup>[15]</sup>实现零件的分割。在此基础上利用 YOLOv3 算法对锯链零件进行缺陷检测。改进 FPN 特征

金字塔结构,融合锯链图像的浅层与深层特征;使用 K-means++ 聚类算法代替 K-means 算法,优化先验框参数信息;引入 GIoU 边框回归损失函数,提高锯链缺陷预测框的定位精度。最后搭建一套锯链缺陷在线检测系统,对所提方法进行验证。实验结果表明,所提方法对弱光环境下的锯链缺陷检测具有较快的检测速度和较高的检测精度。

## 1 基于 RRDNet 模型弱光增强锯链图像

本文将 RRDNet 网络模型应用于弱光情况下的锯链缺陷检测。该模型是在 Retinex 模型<sup>[16]</sup>基础上引入了噪声分量,调整图像照明度并去除部分噪声,从而生成高可见度图像。RRDNet 模型框架包括两个部分,分解和调整。

### 1.1 分解阶段

RRDNet 模型在分解阶段是一个三支卷积神经网络,将图像分解成照度  $S$ 、反射率  $R$  和噪声  $N$  三部分,如图 1 所示。

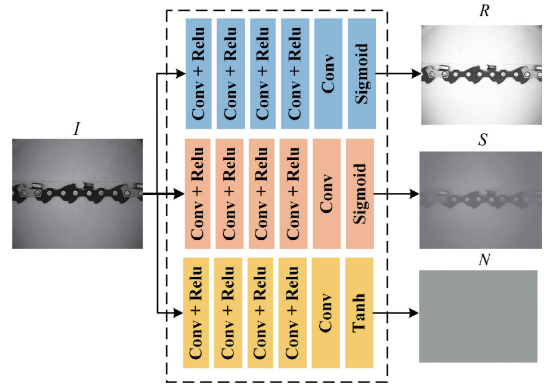


图 1 RRDNet 分解阶段

图像  $I$  可以表示为:

$$I = R \times S + N \quad (1)$$

照度和反射率分别经过多个卷积和池化操作后,采用 Sigmoid 激活函数将变量压缩在  $[0, 1]$  之间,而噪声分量则在最后一层使用 Tanh 函数将值压缩在  $[-1, 1]$  之间。接着通过损失函数和权重更新的不迭代完成图像分解。损失函数由如下三部分组成:

$$L = \lambda_{re} L_{re} + \lambda_{te} L_{te} + \lambda_n L_n \quad (2)$$

式中:  $L_{re}$ 、 $L_{te}$ 、 $L_n$  分别表示 Retinex 重构损失、纹理细节损失和噪声损失,  $\lambda_{re}$ 、 $\lambda_{te}$ 、 $\lambda_n$  分别表示对应的权重系数。

根据 Retinex 分解理论,将  $R$ 、 $G$ 、 $B$  三通道最大的  $S_0$  估为照明的初始值,使用  $I_1$  范数估计出清晰的照明和反射率,Retinex 重构损失具体计算如下:

$$L_{re} = \|I - (R \cdot S + N)\|_1 + \|S - S_0\|_1 + \|R - \frac{I}{S}\|_1 \quad (3)$$

纹理细节损失通过光照损失来表示,对于低照度图像亮度接近的相邻像素,将它们除以相同的  $[0, 1]$  之间的数值

时,两者之间照度将被同时放大。通过垂直、水平两个方向来计算:

$$L_{te} = \| \omega_x \cdot (\partial_x S)^2 \|_1 + \| \omega_y \cdot (\partial_y S)^2 \|_1 \tag{4}$$

式中:  $\omega_x$ 、 $\omega_y$  分别表示  $x$ 、 $y$  方向估算的权重系数。

$$\omega_x = \frac{1}{G \circ (\partial_x I_g)^2} \tag{5}$$

式中:使用  $G$  表示高斯滤波,  $\circ$  表示卷积运算,  $I_g$  为输入的灰度图。

根据 Retinex 理论通过拉伸对比度提高亮度的方法会导致噪声也不可避免地被放大,RRDNet 通过估计照度图来估计噪声,具体计算如下所示:

$$L_n = \| I \cdot N \|_F + \frac{1}{\lambda_n} [ \| \omega_r \cdot (\partial_x R)^2 \|_1 + \| \omega_r \cdot (\partial_y R)^2 \|_1 ] \tag{6}$$

式中:使用 Frobenius 范数来估算损失值,  $\omega_r$  为引导系数,它通过归一化函数  $normalize$  进行估算,具体计算如下:

$$\omega_r = normalize \left( \frac{1}{I \cdot (\partial_x R)^2 (\partial_y R)^2} \right) \tag{7}$$

至此完成损失值的计算,完成输入图像的分解。

1.2 调整阶段

照度分量经过 gamma 变换,更新  $S$  值。接着根据分解

阶段的式(1)估算反射率,使用更新后的  $\hat{S}$  和  $\hat{R}$  重构图像,完成图像的调整。调整阶段过程如图 2 所示。具体计算公式如下:

$$\hat{S} = S^\gamma \tag{8}$$

式中:  $\gamma$  为 gamma 因子。

$$\hat{R} = \frac{I - N}{S} \tag{9}$$

$$\hat{I} = \hat{R} \cdot \hat{S} \tag{10}$$

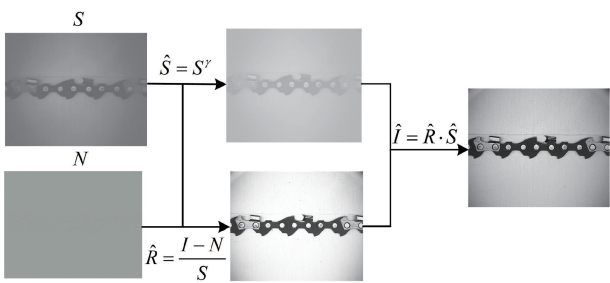


图 2 RRDNet 调整阶段

2 基于改进 YOLOv3 模型的锯链缺陷检测

尽管利用 YOLO 系列模型可实现快速有效的目标检测部署,但在特定场景下仍需针对性改进。针对锯链缺陷检测,应用 YOLOv3 为锯链缺陷检测模型的必要性如下:

1) 锯链缺陷种类多样,铆钉漏铆、连接片倒装类小尺寸缺陷在经过 RRDNet 照度增强后,使用改进 YOLOv3 算法能够满足检测需求。2) 综合考虑计算资源和部署难度,将锯链

检测应用在 YOLOv3 上较为合适。

2.1 网络结构改进

采用 Darknet-53 作为 YOLOv3 特征提取主干网络<sup>[17]</sup>,Darknet-53 网络结构如图 3 所示。

	类型	卷积核数量	尺寸/步长	输出
×1	卷积	32	3×3	416×416
	卷积	64	3×3/2	208×208
	卷积	32	1×1	
	卷积	64	3×3	
	残差			208×208
×2	卷积	128	3×3/2	104×104
	卷积	64	1×1	
	卷积	128	3×3	
×8	残差			104×104
	卷积	256	3×3/2	52×52
	卷积	128	1×1	
	卷积	256	3×3	
×8	残差			52×52
	卷积	512	3×3/2	26×26
	卷积	256	1×1	
	卷积	512	3×3	
×4	残差			26×26
	卷积	1 024	3×3/2	13×13
	卷积	512	1×1	
	卷积	1 024	3×3	
	残差			13×13

图 3 Darknet-53 网络结构

不同于其他卷积神经网络,Darknet-53 多采用 11、33 大小的卷积核,通过调整卷积核移动步长的方式进行 5 次下采样,代替了池化层的作用。引入多尺度融合的目标检测方法,输出 3 种尺度的特征图层用于预测大、中、小尺寸的目标物,并将特征图层上采样处理,融合各层特征。YOLOv3 算法对于 416 416 的输入图像在预测阶段会将各输出特征图层划分为 1 313、2 626、5 252 大小的网格,最大预选框数量有 3 549 个。

本文在原有 YOLOv3 的基础上将浅层特征与深层特征进一步融合,如图 4 所示,DBL 中每层卷积层(convolutional layer, CONV)后都加入批标准化(batch normalization layer, BN)和 Leaky Relu 激活函数,提升了特征提取的效率,网络中引入 res 残差块解决了训练过程中梯度下降缓慢的问题,避免了由于网络层数过深导致特征提取不明显。上采样将小尺寸特征图放大两倍,并将其与大尺度特征图进行融合,最终输出特征图层。

FPN 改进部分如图 4 虚线框所示。在 FPN 中增加输出预测特征图的尺度,将 Darknet-53 网络中第 2 个残差块的输出特征与经过 2 倍上采样的特征图层融合,再经过卷积核大小为 11 的卷积层,形成新的输出特征图层,新的特征图层将网络的特征提取效果进一步提高,网格数量进一步划分为 104×104。在增加一层特征图层后,先验框的总数由原来的 9 个增加到了 12 个,对输入图片的最大预选框数量可以达到 14 365 个,相比原始 YOLOv3 预选框数量扩大了 4 倍,增加了网络对不同尺寸类型的锯链零件缺陷的预测能力,降低缺陷漏检的概率。

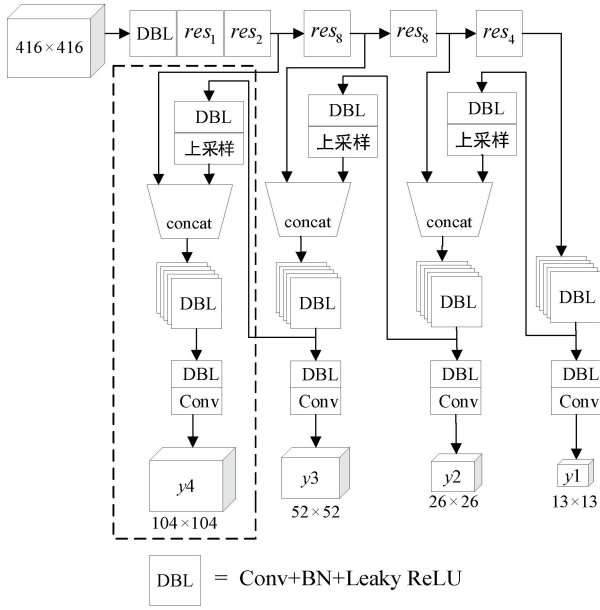


图4 改进的YOLOv3网络结构图

## 2.2 先验框参数信息优化

YOLOv3中各特征图层先验框的尺寸是通过K-means聚类算法在VOC数据集上获得的,锯链缺陷与VOC数据集形状、大小差异较大,导致在预测过程中边界框标注范围与缺陷目标不匹配。因此,需要对锯链数据集重新聚类,计算YOLOv3网络各输出特征图层中先验框尺寸大小。

K-means对初始点的随机选取计算得到了聚类中心,得到各类先验框的大小有利于最后生成的预测框更加匹配目标物,K-初始点的选择对于聚类结果有很大的影响。因此,本文选用K-means++聚类算法生成12个聚类中心,具体步骤如下:

1)根据标注信息,随机选择一个样本作为第一个聚类中心 $k_1$ ,设置12个聚类中心。

2)计算每个样本与聚类中心 $k_1$ 之间的IoU距离,以及被选为下一个聚类中心的概率,最后根据轮盘法选择一个聚类中心。距离计算公式如下所示:

$$d_{ij} = \sqrt{[B_i(x) - C_j(x)]^2 + [B_i(y) - C_j(y)]^2} \quad (11)$$

式中: $B_i(x)$ 、 $B_i(y)$ 第 $i$ 个样本点的横、纵坐标, $C_j(x)$ 、 $C_j(y)$ 为第 $j$ 个聚类中心的横纵坐标。并重复该步骤,直到选择出12个聚类中心。

3)计算每个样本到12个聚类中心的IoU距离,并将其分配到距离聚类中心最小的簇中。

4)重新计算聚类中心,具体计算如下:

$$k_i = \frac{1}{|k_i|} \sum_{n \in k_i} n \quad (12)$$

式中: $k_i$ 为第 $i$ 个聚类中心, $n$ 为样本总量。

5)重复步骤3)和4),直至聚类中心不再变化。

在锯链缺陷数据集上,聚类后的先验框参数信息如表1所示。

表1 先验框参数信息

特征图层	先验框参数信息	特征图层	先验框参数信息
$13 \times 13$	(90,75)	$13 \times 13$	(90,75)
$26 \times 26$	(80,93)	$26 \times 26$	(80,93)
$52 \times 52$	(71,69)	$52 \times 52$	(71,69)
$104 \times 104$	(40,54)	$104 \times 104$	(40,54)

## 2.3 损失函数改进

原网络采用IoU Loss作为预测框损失函数存在一些不足:当预测框与标注框不存在重叠区域时,模型无法继续优化预测框,无法提供准确的位置信息;预测框与标注框在不同方向存在重叠区域且重叠区域面积相等时,IoU值相同,但不能体现预测框与标注框的重合程度。因此,本文提出引入GIoU来弥补IoU的不足。

GIoU在两框无限重合的情况下取1,在两框没有重叠区域且无限远的情况下取-1,可更好的反映重合程度。IoU、GIoU及GIoU损失函数分别如式(13)~(14)所示。引入GIoU后的总损失函数如式(15)所示。

$$\text{IoU} = \frac{|B_1 \cap B_2|}{|B_1 \cup B_2|} \quad (13)$$

$$\text{GIoU} = \text{IoU} - \frac{|C - (B_1 \cap B_2)|}{|C|} \quad (14)$$

$$L_{\text{GIoU}} = 1 - \text{GIoU} \quad (15)$$

式中: $B_1$ 为预测框, $B_2$ 为标注框, $C$ 为 $B_1$ 、 $B_2$ 并集的最小外接矩形区域, $L_{\text{GIoU}}$ 为GIoU边框回归损失函数。

$$\begin{aligned} \text{Loss} = & \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} (1 - \text{GIoU}) + \\ & \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} (C - \hat{C}_i)^2 + \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{noobj}} (C - \hat{C}_i)^2 + \\ & \sum_{i=0}^{S^2} l_{ij}^{\text{obj}} \sum_{C \in \text{Classes}} (p_i(c) - \hat{p}_i(c))^2 \end{aligned} \quad (16)$$

式中: $\lambda_{\text{coord}}$ 为权重系数, $\lambda_{\text{noobj}}$ 为惩罚系数, $S$ 为图像网格划分分数, $B$ 为每个网格内预测框个数, $C$ 为缺陷类别数量, $p$ 为属于某个类别的概率, $c$ 为缺陷种类编号。 $l_{ij}^{\text{obj}}$ 为第 $i$ 个网格中的第 $j$ 个预测框是否包含物体,包含物体置1,否则置0。

## 3 实验及评估

### 3.1 视觉检测系统的搭建

为实现锯链的智能化检测,搭建了一套锯链缺陷在线检测系统,该系统主要由运动控制模块、图像采集与检测模块和结果显示与输出模块构成。系统工作原理图如图5所示。

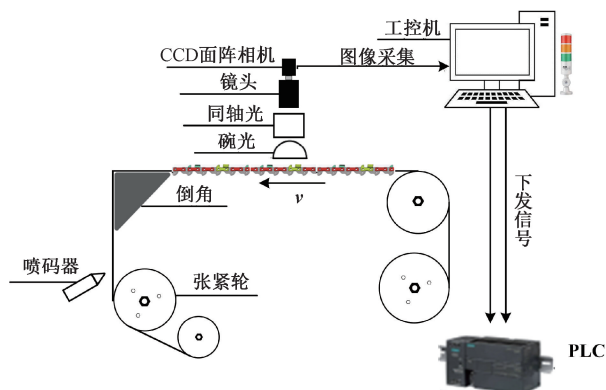


图 5 系统工作原理图

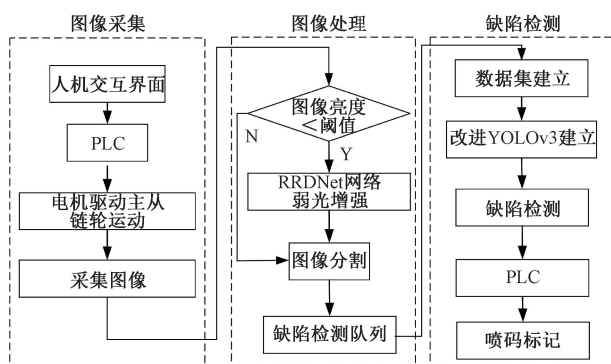


图 7 系统工作流程图

1) 运动控制模块由 PLC、电机、气缸、电磁阀等组成, 完成系统正常运行、停止、接收上位机命令以及检出缺陷时控制电磁阀通断的功能, 达到缺陷检测与标记的目的。

2) 图像采集与检测模块主要由工控机、CCD 面阵相机、相机支架、镜头、同轴光和碗光组成。相机每隔 1.8 s 捕获一张锯链图像, 每张锯链图像包含 9 个完整的零件。

3) 结果显示与输出模块。借助 QT Creator 平台设计人机交互界面, 将缺陷结果进行可视化显示。记录缺陷检出数量、总检测锯链数量和良品率统计的结果, 便于实时查看锯链零件的质量。

该系统与锯链生产设备直接连接, 实现链条从生产到检测生产线一体化。系统应用场景图如图 6 所示。



图 6 系统实际应用场景图

系统工作流程: 在计算机的人机交互界面上启动系统, PLC 控制系统驱动步进电机转轴带动主动组件旋转运动, 当锯链移动至上下工位拍照组件下方或上方时, CCD 面阵相机进行图像采集, 并于可视化界面显示采集结果。工控机对输入图像进行弱光增强处理, 增强后的图像进行自适应分割处理, 并将零件分割图放入缺陷检测队列, 使用改进后的 YOLOv3 对数据集进行缺陷检测。若存在缺陷, 软件输出缺陷名称并向 PLC 发送缺陷检出指令, PLC 接收到指令后, 控制喷码器在缺陷位置喷码标记, 并将结果于界面显示。系统整体的工作流程如图 7 所示。

### 3.2 弱光增强性能测试

本实验中的图像处理算法是在 Windows 操作系统下, 基于 Opencv 计算机视觉库, 采用 Python3.9 进行编写和测试。RRDNet 模型参数设置:  $\lambda_{re} = 1, \lambda_{te} = 3, \lambda_n = 5000, \gamma = 0.4$ 。使用自然图像质量评估器 (natural image quality evaluator, NIQE)<sup>[18]</sup>、峰值信噪比 (peak signal-to-noise ratio, PSNR)、平均亮度和平均梯度<sup>[19]</sup>作为图像增强的评价指标。NIQE 用于评估弱光增强后图像的整体质量效果, NIQE 数值越低, 图像质量越高; PSNR 用于衡量原图与增强后图像之间的相似程度, 数值越高损失越小; 平均亮度反映图像整体的亮度, 影响信息获取的容易程度; 而平均梯度则反映了图像细节的变化情况, 梯度值越大代表图像信息越丰富。

为了更好地评估实际工厂生产装配过程中的照度变化情况下 RRDNet 模型的性能,

将视觉系统连接在现场装配线上进行实测。采集机台工作 1 天、3 天、5 天后的锯链图像, 分别构成 A、B、C 三组数据集, 每组随机挑选锯链图像 200 张进行后续实验测试。

使用 RRDNet 模型对 3 组不同时段的锯链图像进行照度增强, 采集结果和恢复结果如图 8 所示, 第 1 行为每组的原始图像, 第 2 行为增强后的效果图, 图片左上角显示了质量评价指标。由 3 组数据集的评估指标, 可以发现随着机台工作时间的增加, 图像质量和亮度逐渐降低。而经过 RRDNet 模型训练后可以降低 NIQE, 这是因为 RRDNet 模型中的噪声估计分量能够自然调整暗区细节, 改善图像质量。A、B、C 三组数据集的 NIQE 值分别降低了约 0.03、0.19 和 0.21。网络对于照度更低的数据集图像质量恢复程度更大。根据图像可视化和平均亮度指标可以发现图像亮度显著提高, 但当原图平均亮度为 71.39 时, 即 C 组极端黑暗的情况下恢复效果较差。这是因为原图照度过低, 恢复后的图像亮度仍位于平均亮度阈值以下, 因此需对 C 组数据集进行二次训练。二次训练的实验结果如图 9 所示, 并使用图 10 图像亮度直方图来进一步显示增强后像素值的分布。结果显示经过二次训练的锯链图像能够满足图像质量的恢复需求。

将本文使用算法与典型的图像增强算法于现场采集的锯链图像上进行实验对比,进一步验证算法有效性。为突出对比效果,使用一款油污、粉尘干扰严重情况下的锯链进

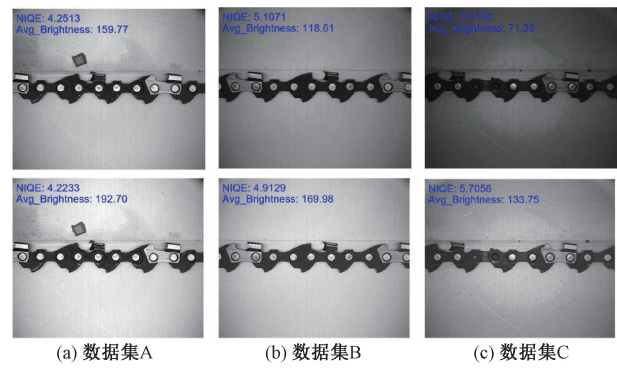


图 8 RRDNet 的恢复结果

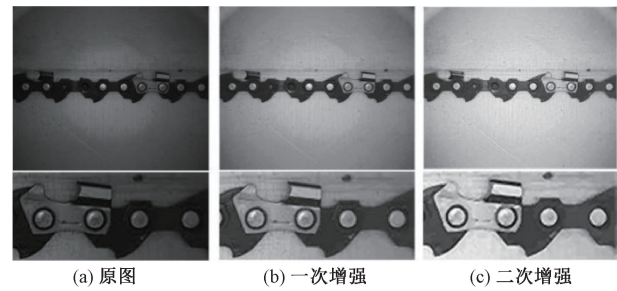


图 9 训练结果

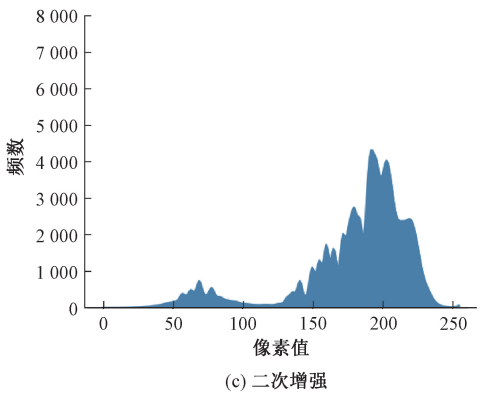
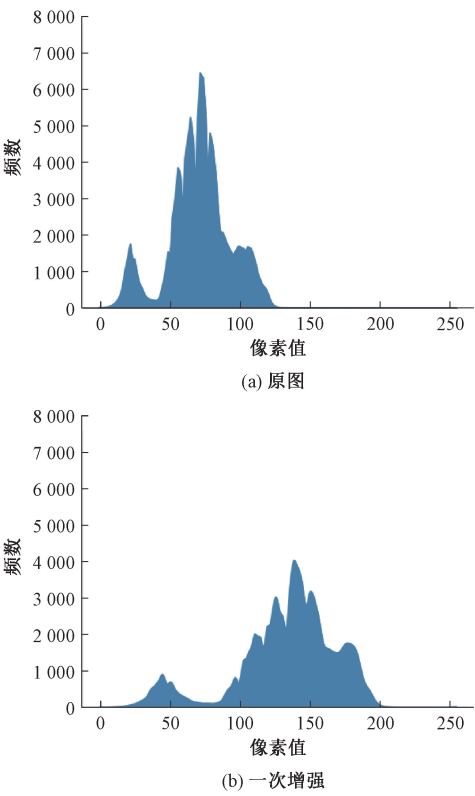


图 10 图像直方图

行实验验证。各算法对锯链图像的增强结果如图 11 所示,评价指标如表 2。可知经过 Retinex 算法增强的图像其 PSNR 和平均亮度值较低,说明图像损失严重,照度增强能力有限,而且该算法并未考虑到噪声干扰,导致图像亮度和细节恢复程度都较低;BIMFF 算法<sup>[20]</sup>虽然能够提升图像质量,但是亮度增强和去噪效果不佳,背景部分的油污影响仍明显;URetinex 算法<sup>[21]</sup>虽然增强后的图像亮度值较高,但结果图的局部亮块区域突出,增强效果不均匀,使传动片零件边缘产生曝光,影响细节特征;相比之下本文使用算法在对锯链图像进行弱光亮度增强的同时兼顾去除噪声干扰,得到了更多的细节信息。

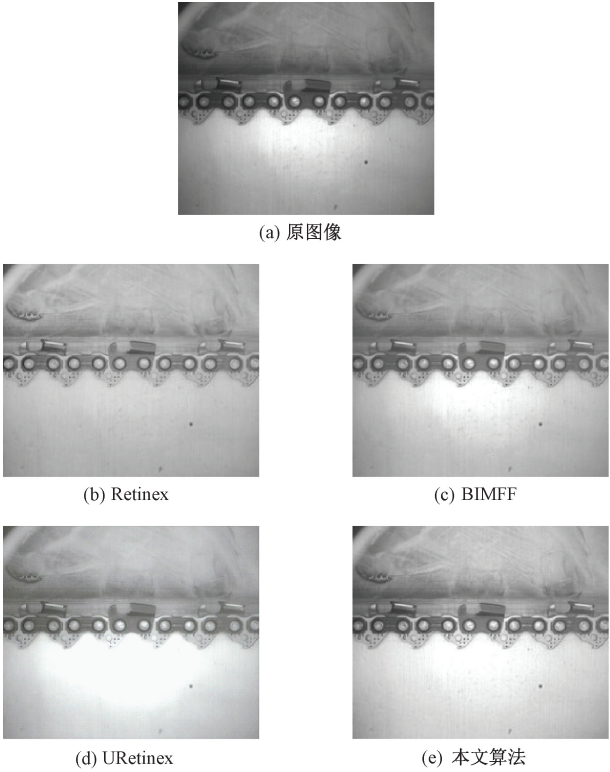


图 11 不同弱光增强算法性能比较

表 2 不同算法性能指标的比较

指标	原图	Retinex	BIMFF	URetinex	本文算法
平均亮度	139.177	175.043	172.149	202.091	185.211
平均梯度	33.109	36.121	35.355	34.447	42.815
NIQE	5.883 3	3.198 2	3.353 7	3.860 2	2.952 7
PSNR	—	13.906	15.500	13.621	17.272

3.3 图像分割效果

为实现锯链缺陷的精准定位,需要先对锯链零件进行分割。采用课题组之前研究的分割算法进行实验,验证弱光环境下的分割性能。对比分析 RRDNet 网络增强对锯链零件分割算法性能的影响。

将增强前后的 A、B、C 三组锯链图像输入分割算法中进行测试,结果如表 3 所示。对锯链图像进行增强处理,使分割算法正确率显著提升。这是因为锯链零件是通过铆钉位置坐标和零件之间固有的装配距离进行分割,而弱光环境下的漏铆、铆裂特征因油污、粉尘等干扰影响变得模糊,降低了霍夫圆算法定位效果,从而使分割性能下降。而 RRDNet 网络使漏铆等暗区细节更加清楚,使铆钉位置定位更为准确。因此在对锯链零件检测前,使用弱光增强方法能够为后续缺陷检测提供更加精确、简便的数据集。分割结果如图 12 所示。

表 3 弱光增强对图像分割算法性能的影响

分割算法	正确分割图像数量	分割正确率/%
增强前	465	77.5
增强后	554	92.3

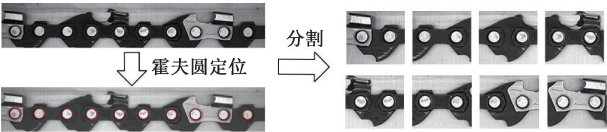


图 12 锯链分割效果图

3.4 改进 YOLOv3 缺陷检测算法性能测试

1) 缺陷检测数据集的建立

实验数据集由在线检测系统在自然光条件下进行采集。由于锯链出现缺陷概率较小,为降低训练时过拟合,增强网络泛化能力,需要大量的图片训练。因此,需要对图片进行数据增强。原数据集 1 200 张,采用图像平移、增加随机噪声的方法扩充数据集图片至 2 491 张。训练集与测试集按照 8 : 2 比例随机划分。使用深度学习工具 labelImg 对图片缺陷进行类别和位置标记,生成含有标注信息的 txt 格式的文件。

2) 性能评价指标

$mAP$  为所有类别缺陷的平均检测精度,用于衡量模型整体泛化性能,  $fps$  衡量模型的检测速度,计算公式如式下所示:

$$mAP = \frac{\sum_{j=0}^N AP(j)}{N} \quad (17)$$

$$fps = \frac{N_p}{T} \quad (18)$$

式中:  $AP(j)$  为第  $j$  类缺陷的检测精度,  $N$  为总体缺陷类别数量;  $N_p$  为预测图片总数量,  $T$  为预测总时间。

3) 训练与检测过程

本文的锯链缺陷智能化检测方法的实验模型运行在 Ubuntu18.04 操作系统的服务器上,安装有 CUDA11.1 版本环境和 Pytorch 深度学习框架,采用 Tesla P100 系列 GPU 进行训练加速。训练迭代 2 000 轮次,采用 Adam 优化器, Batch size 设置为 64, 初始学习率设为 0.001, 学习率衰减系数设为 0.000 5。改进后的 YOLOv3 算法迭代训练中的损失值变化如图 13 所示。可以观察到,在前 500 次迭代中,训练损失下降速度非常快。随着迭代训练进行至 1 500 轮次,损失值的变化逐渐趋于稳定,并最终收敛于约 0.1 的数值范围。

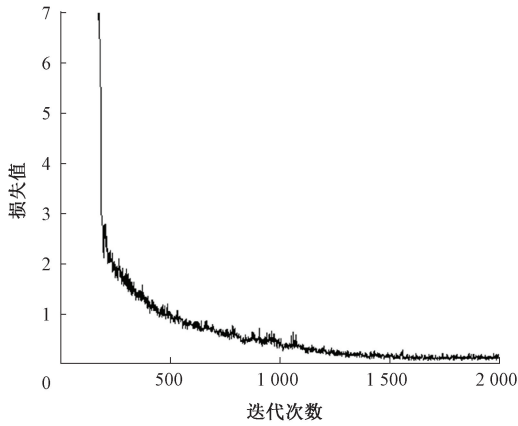


图 13 损失值-迭代次数曲线

4) 系统整体测试

为验证本系统所提方法在弱光环境下的缺陷检测精度,对生产现场的 1 200 条锯链进行缺陷检测实验,锯链中含有刀片破损、连接片混料、铆钉铆裂等缺陷共 154 处。以工业应用中常用的过检率  $y_0$  和漏检率  $y_1$  作为目标检测的性能指标,具体计算公式如下:

$$\begin{cases} y_0 = (n_1 - n_0) / n_1 \times 100\% \\ y_1 = (X - n_0) / X \times 100\% \end{cases} \quad (19)$$

式中: 检出缺陷数  $n_1$  为算法实际检测到的缺陷数量, 包含错检现象; 实际缺陷数  $n_0$  为检出缺陷数  $n_1$  中真实存在缺陷的数量。  $X$  为实际缺陷数量, 本文中  $X = 154$ 。

改进前后模型的检测效果如表 4 所示, 由表可知弱光环境下直接使用 YOLOv3 算法检测漏检率高达 68.8%, 改进算法的过检率和漏检率仍较高。这是因为网络特征提取能力受到暗区模糊特征影响, 导致识别率低。图像增强后, 使原模型的过检率与漏检率分别降至 12.5% 和 27.3%, 改进后的网络

则降低到了 9.14%和 3.2%,满足产品的质检需求。

表 4 不同方法下锯链缺陷检测结果对比

图像类型	YOLOv3 算法	实际缺陷数	检出缺陷数	过检率	漏检率
		$n_0$	$n_1$	$y_0/\%$	$y_1/\%$
原始图像	原始 YOLOv3	48	65	26.1	68.8
改进图像	改进 YOLOv3	75	95	21.0	53.2
增强图像	原始 YOLOv3	112	128	12.5	27.3
改进图像	改进 YOLOv3	149	164	9.1	3.20

采用不同算法在自制锯链数据集上的检测性能如表 5 所示,其中方法 1:在 YOLOv3 中使用 K-means++ 聚类,方法 2:在 YOLOv3 中使用 K-means++ 聚类算法并引入 GIoU 边框损失函数。改进后算法为 92.88%,比原始 YOLOv3 提高了 14%,表明本文算法的检测精度优于原始 YOLOv3 算法。方法 1 和方法 2 比本文算法的精度分别低了 9.27%和 2.35%,是由于本文算法中新的特征图层能够提取到更多的特征信息。Faster R-CNN 的  $mAP$  低于本文算法 4.16%,相对原始 YOLOv3 算法和方法 1 有一定优势,但检测速度最慢。本文算法的检测速度为 51 fps,略低于方法 1 和方法 2,但检测精度最高,这是由于 YOLOv3 网络结构中增加了输出特征图层的尺度,GIoU 边框回归损

失函数以及 K-means++ 聚类共同改进的结果。综上所述,本文算法的综合检测性能最优,满足实际锯链检测精度的要求。


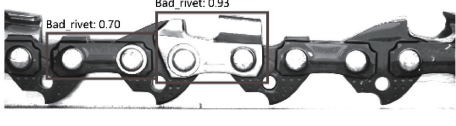

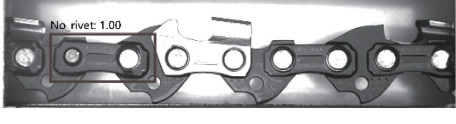
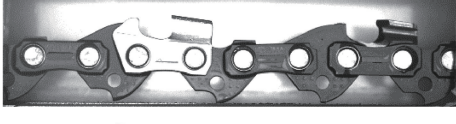

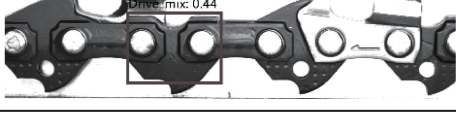

表 5 算法测试性能对比

算法	$mAP/\%$	fps
Faster R-CNN	88.72	39
原始 YOLOv3	78.88	55
方法 1	83.61	55
方法 2	90.53	55
本文算法	92.88	51

5)检测结果

表 6 所示为使用原始 YOLOv3 和本文改进的算法对锯链表面缺陷进行检测对比图,其中第 1 列为使用原始 YOLOv3 进行缺陷检测的效果,第 2 列为本文算法的检测效果。由表可知,原始 YOLOv3 算法未完全标注出传动片混料位置整个缺陷区域,且对于连接片倒装类缺陷存在漏检情况,没有预测到缺陷的位置。使用本文改进算法在铆钉铆裂和传动片混料类的缺陷检测中预测框位置与缺陷位置更加匹配,成功检测出连接片倒装类的缺陷。因此,本文算法对缺陷的检测精度整体高于原始算法,且对缺陷位置的预测更加准确。

表 6 算法检测结果对比

图像类型	原始 YOLOv3 算法	本文算法
铆钉铆裂		
铆钉漏铆		
连接片倒装		
传动片混料		

4 结 论

为实现复杂环境下锯链缺陷自动化检测,本文设计了一种基于弱光增强和 YOLO 算法的锯链缺陷检测方法。采用 RRDNet 网络模型实现复杂环境下锯链照度的自适应增强,并提出一种改进 YOLOv3 的缺陷检测算法,从网

络结构、聚类算法、边框回归损失函数三方面改进此算法,提高了对小目标缺陷特征的检测精度。测试结果表明,改进的 YOLOv3 算法锯链缺陷检测的平均检测精度为 92.88%,较原有 YOLOv3 算法提高了 14%,检测速度保持在 51 fps,可在实际应用中准确识别、分类与定位锯链缺陷,实现锯链缺陷的智能化检测。最后对搭建的检测平台

于弱光环境下进行系统整体测试,系统漏检率和过检率仅为 3.2% 和 9.1%,满足企业生产需求。本文所提方法通过 RRDNet 网络和改进 YOLOv3 算法,全局增强图像照度和质量,强化锯链的有效特征,实现零件缺陷的精确检测。但在实际检测过程中仍存在因环境干扰造成的局部对比度较低的情况,增加了系统误检和漏检率。下一步将针对这一问题进行改进,尝试采取特定的预处理措施,开发鲁棒性更强的缺陷检测算法,以提升检测的准确性和可靠性。

## 参考文献

- [1] 刘九庆,张俊杰,朱斌海.电链锯锯切试验台设计及影响锯切性能因素的遴选[J].东北林业大学学报,2021,49(11):116-120.
- [2] 卢云峰,王俊豪,杨绍荣.非手动式锯链制动器性能要求和检测方法探讨[J].电动工具,2020(5):12-16.
- [3] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [4] REN S, HE K, 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, 2016, 39(6): 1137-1149.
- [5] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]. European Conference on Computer Vision. Springer, Cham, 2016: 21-37.
- [7] 马晨凯,吴毅慧,傅华奇,等.基于深度学习的先进陶瓷零件实时缺陷检测系统[J].南京航空航天大学学报,2021,53(5):726-734.
- [8] 李维刚,叶欣,赵云涛,等.基于改进 YOLOv3 算法的带钢表面缺陷检测[J].电子学报,2020,48(7):1284-1292.
- [9] 刘笑楠,白雨辰,尹思璐,等.基于类卷积神经网络的可见光虹膜识别方法[J].仪器仪表学报,2017,38(11):2651-2658.
- [10] WANG Y, WANG Y, LI Y, et al. Adaptive enhancement algorithm for low illumination images with guided filtering-Retinex based on particle swarm optimization[J]. Journal of Ambient Intelligence and Humanized Computing, 2022, 14(10):13507-13522.
- [11] TIAN Z J, WANG M L, WU J, et al. Mine image enhancement algorithm based on dual domain decomposition[J]. Acta Photonica Sin, 2019, 48(5): 107-119.
- [12] HU W, WANG T, WANG Y, et al. LE-MSFE-DDNet: A defect detection network based on low-light enhancement and multi-scale feature extraction[J]. The Visual Computer, 2022, 38(11): 3731-3745.
- [13] HUI Y, WANG J, SHI Y, et al. Low light image enhancement algorithm based on detail prediction and attention mechanism[J]. Entropy, 2022, 24(6): 815.
- [14] ZHU A, ZHANG L, SHEN Y, et al. Zero-shot restoration of underexposed images via robust retinex decomposition [C]. 2020 IEEE International Conference on Multimedia and Expo(ICME), 2020 Jul 6(pp. 1-6).
- [15] 陈励威,刘苏苏,袁辉,等.融合装配特征和回归分析的锯链图像分割算法[J].电子测量技术,2022,45(23): 139-146.
- [16] WEI C, WANG W, YANG W, et al. Deep retinex decomposition for low-light enhancement[J]. ArXiv Preprint, 2018,ArXiv:1808.04560.
- [17] WANG K, LIU M. YOLOv3-MT: A YOLOv3 using multi-target tracking for vehicle visual detection[J]. Applied Intelligence, 2022, 52(2): 2070-2091.
- [18] ZHANG Y, ZHANG J, GUO X. Kindling the darkness: A practical low-light image enhancer[C]. Proceedings of the 27th ACM International Conference on Multimedia, 2019: 1632-1640.
- [19] 杨爱萍,赵美琪,宋曹春洋,等.基于色调映射和暗通道融合的弱光图像增强[J].天津大学学报(自然科学与工程技术版),2018,51(7):768-776.
- [20] YING Z, LI G, GAO W. A bio-inspired multi-exposure fusion framework for low-light image enhancement[J]. ArXiv Preprint,2017, ArXiv:1711.00591.
- [21] WU W, WENG J, ZHANG P, et al. Uretinex-net: Retinex-based deep unfolding network for low-light image enhancement[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 5901-5910.

## 作者简介

张福豹,副教授,硕士研究生导师,主要从事智能检测与装备方面的研究与教学。

E-mail:zhang.fb@ntu.edu.cn

吴婷,硕士研究生,主要研究方向为图像处理与智能制造。

E-mail:wting@stmail.ntu.edu.cn

刘苏苏(通信作者),讲师,博士,主要研究方向为图像处理与智能制造。

E-mail:liususu1006@139.com