

改进 YOLOv5 的输送带缺陷检测^{*}

张宏飞 冯永利 黄金凤

(华北理工大学机械工程学院 唐山 063210)

摘要: 针对带式输送机的输送带缺陷检测因没有公开的数据集、缺陷形状多样化、撕裂长短不一而导致检测的精度低的问题,本文将使用线阵相机,并在拍摄过程中采用线激光作为辅助工具,减轻恶劣环境对图像的影响,并提出改进 YOLOv5 的输送带缺陷检测算法,以保证煤矿的生产安全。首先,在现有数据的基础上,通过多种数据增强方式进行组合的方法进行扩充。然后在特征提取阶段,用类似注意力机制的 C3_A 替换 Backbone 中的 C3 模块,以提高整体性能。接着在特征融合阶段,采用短接的方法将 Backbone 与 Neck 的 PAN 结构结合,以减少特征信息丢失。最后,在损失函数上融入微调后的交并比并设置两个参数,对原始交并比进行缩放和裁剪,有效约束模型预测框与真实框的位置关系,进一步提升了模型对边界框回归的准确性。实验结果表明,输送带缺陷检测的平均精度均值达到 88.1%,精确率达到 88%,召回率达到 86.5%,满足输送带缺陷的检测要求。

关键词: 缺陷检测;YOLOv5;数据增强;结构短接;交并比

中图分类号: TN919.2 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Improving YOLOv5 conveyor belt defect detection

Zhang Hongfei Feng Yongli Huang Jinfeng

(College of Mechanical Engineering, North China University of Technology, Tangshan 063210, China)

Abstract: Aiming at the problem of low detection accuracy of conveyor belt defect detection of belt conveyor due to the lack of public data sets, the diversification of defect shapes and the different lengths of tearing, this paper will use linear array camera and use linear laser as an auxiliary tool in the shooting process to reduce the influence of harsh environment on the image, and put forward an improved YOLOv5 conveyor belt defect detection algorithm to ensure the production safety of coal mine. Firstly, on the basis of the existing data, the method of combining multiple data enhancement methods is extended. Then, in the feature extraction stage, the C3 module in Backbone is replaced with a C3_A similar to the attention mechanism to improve the overall performance. Then, in the feature fusion stage, the short-circuit method is used to combine the PAN structure of Backbone and Neck to reduce the loss of feature information. Finally, the fine-tuned intersection-union ratio is integrated into the loss function and two parameters are set. The original intersection-union ratio is scaled and cropped, which effectively constrains the position relationship between the model prediction box and the real box, and further improves the accuracy of the model's boundary box regression. The experimental results show that the average accuracy of conveyor belt defect detection is 88.1%, the accuracy rate is 88%, and the recall rate is 86.5%, which meets the detection requirements of conveyor belt defects.

Keywords: defect detection;YOLOv5;data augmentation;structural short circuiting;intersection and comparison

0 引言

带式输送机具有长距离运输能力、运行效率高、耐用不易损坏,以及易于自动控制等优点^[1],在运输过程中起着极为关键的作用。其在超负荷运行、物料堆积、带材老化磨损、异物损伤或不当维护等情况下容易导致输送带损坏,这

不仅降低了运输效率,还可能引起人员伤亡和经济损失^[2-3]。因此,利用先进的监测和自动化技术进行快速准确的输送带缺陷检测非常重要。

输送带缺陷检测方法经历了接触式检测和非接触式检测两个阶段。早期的输送带缺陷检测以接触式为主,例如:棒形检测法^[4]、漏料检测法^[5]、浮动托辊检测法^[6]、压力检

测法^[7]等。接触式检测方法虽然操作简便,但准确性较低,在可靠性和检测精度上不足,并且极易受灰尘的干扰。闭合线圈法^[8]、X 射线检测法^[9]、电磁感应检测法和机器视觉检测法属于现有非接触式输送带缺陷的检测方法。其中机器视觉检测法^[10-11]因其优越的安全性、准确性和稳定性,以及智能化、可视化的特点受到了广泛的应用。而且机器视觉的引入使表面缺陷检测的人工操作减少,维护简单,提升了检测过程的自动化水平,因此被推崇为最理想的解决方案。但需要高质量的图像输入,采集成本较高,且对光照和环境条件敏感。

目前机器视觉方法通常使用线激光作为强光源,以降低环境干扰并提升图像质量,解决因昏暗、潮湿和大量粉尘导致的输送带图像模糊问题。李海滨等^[12]借助线激光进行辅助识别,依靠提取亚像素精度的光条中心并利用中心曲率来判断撕裂特征,成功减少了计算量。然而,输送带表面划伤对该方法有较大的干扰,同时需要提升光条中心的准确性。王晓超等^[13]利用线激光光源和 CCD 图像,检测输送带下表面的高亮细线。使用无线微分思想将极小范围的曲线作为直线分析,并利用 Hough 变换进行检测,当斜率产生骤变时,表明输送带可能有划痕或撕裂现象,通过实验测试,该方法具有较高的准确性,但在昏暗、潮湿和粉尘大的恶劣环境中仍存在一些局限性,需要进一步改进和优化。虽然在输送带缺陷检测方面,机器视觉检测方法已经取得了不小的进展,但大多限于实验室环境,在实际应用中,其检测精度低、易出错。

为了实现输送带缺陷的准确检测,本文将使用线阵相机,并在拍摄过程中采用线激光作为辅助工具,进一步提升拍摄效果。线阵相机结合线激光拍摄可增强对比度、减少阴影、提高图像清晰度,适合高速检测,提升分辨率和准确性,保证光照一致性,灵活适应不同缺陷,简化后续处理,整体提高检测效率和可靠性。

近年来,深度学习方法被广泛应用于工业缺陷检测中。基于深度学习的目标检测算法主要为一阶段和二阶段。如 Fast R-CNN^[14]系列和 Mask R-CNN^[15]系列是二阶段目标检测算法,虽然检测精度高,但速度较慢。如 SSD^[16]和 YOLO^[17]是一阶段目标检测算法,这类算法平衡了检测的准确性和时效性。Mask R-CNN 在缺陷检测中表现出色,能够适用于不同缺陷的分类和定位,并且直观地表达缺陷的具体形状。然而,其标注成本较高。相比之下, Fast R-CNN、SSD 和 YOLO 等方法适用于单一图像中的缺陷分类问题,但同样面临较高的标注成本^[18]。在工业场景中,实时性对于快速发现和处理缺陷非常重要,尤其是在输送带缺陷检测中。作为一阶段网络的代表,YOLO 算法以其检测速度快和检测精度高的优势,成为当前目标检测研究领域的热门方法。

张梦超等^[19]采用 YOLOv4 tiny 算法对输送带纵向撕裂进行检测。虽然在撕裂较短的情况下检测性能较好,但

缺乏对长撕裂检测性能的验证。周宇杰等^[20]改进 YOLOv4 检测输送带损伤,采用 PANet 结构进行 4 种尺度的特征层融合,提升检测精度达到 96.68% 的同时,忽略了算法增加的参数量并且计算复杂度较高。薄景文等^[21]为了提高检测精度和速度,在 YOLOv3 中使用 Mobilenetv2 改进的同时,在 neck 部分引入 CBAM 用于输送带运输中的杂物检测,但整个模型内存占用较大,只能应用到固定设备。相较传统机器视觉,基于深度学习的方法具有更高的检测精度,但由于输送带图像采集难度大、缺陷形状多样化、撕裂长短不一,仍存在误检、漏检。

将对 YOLOv5 网络的特征提取、特征融合、损失函数分别改进,以提升对缺陷的识别精度,降低误检,漏检,使其在实际应用中更具可靠性和实用性。

1 YOLOv5 算法网络结构

YOLOv5 网络结构如图 1 所示,主要由主干特征提取网络(Backbone)、特征融合网络(Neck)和检测头输出网络(Detect)3 部分组成^[22]。

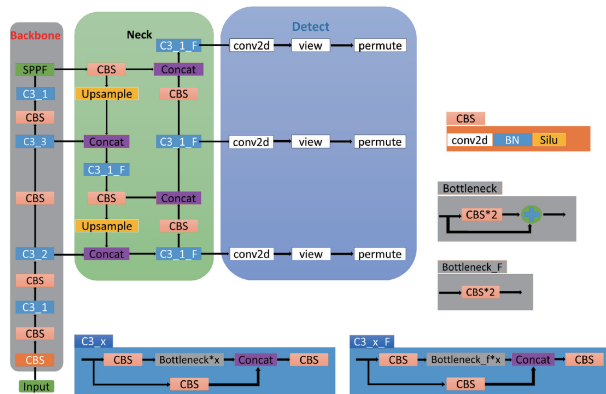


图 1 YOLOv5 网络结构

Fig. 1 YOLOv5 network structure

其中 Backbone 部分主要负责提取输入图像的关键特征,由 CSPDarknet 和 Bottleneck 模块构建。CSPDarknet 是一个双边加权卷积网络,可以有效降低参数数量和计算量。Bottleneck 用于构建深层次的特征提取网络,以高效提取和传递特征信息;Neck 部分主要由特征金字塔网(FPN)和路径聚合网络(PAN)构成,用于将主干网络提取的不同尺度的特征图进行融合和进一步处理,从而提高检测的准确率;Detect 部分通过基于网格的 Anchor 在不同尺度的特征图上实现目标检测的过程。

2 数据集增强与构建

深度学习广泛应用于计算机视觉任务,表面缺陷检测是其在工业领域的具体应用。然而,传统观点认为深度学习难以直接应用于此,主要因为真实工业环境中缺陷样本稀少。相比于 ImageNet 的 1 400 多万张样本,表面缺陷检测常面临小样本问题,许多场景中仅有几张或几十张缺陷

图像^[23]。为解决小样本问题,将现场使用 CMOS 线阵相机,在拍摄过程中采用线激光作为辅助工具,提高图像清晰度,提升分辨率和准确性,保证光照一致性,灵活适应不同缺陷,简化后续处理。

2.1 数据的获取与增强

由于缺乏公开的输送带缺陷数据集,本文通过网络检索和现场采集,但现场采集到的含缺陷的图像数量不足,因此通过网络检索进行补充。部分现场采集图像和网络检索图像如图 2 所示,自制了共 428 张 1 280×800 分辨率的原始图像进行研究,这些图像包含撕裂、表面磨损和破洞 3 种典型的输送带缺陷。采集现场如图 3 所示。由于现有原始图像数量有限,可能会影响模型泛化能力、增加过拟合风险、降低缺陷识别准确率、并引发对研究结果可靠性的质疑。




图 2 部分图像
Fig. 2 Partial images



图 3 采集现场
Fig. 3 Collection site

为解决原始图像数量有限的问题,本文应用了一系列图像增强技术进行扩充,包括添加高斯噪声、随机水平翻转、随机垂直翻转、随机缩放和随机裁剪等,旨在增加样本的多样性,并使模型能够识别不同角度和尺寸的损伤。此外,通过调整图像对比度,进一步模拟实际应用中不同光照条件下的损伤检测场景,从而提高模型的应用性和鲁棒性。特别地,组合使用两种或以上的增强方法,使图像在视觉上更接近实际应用中的多变场景。经过图像增强后,共得到 5 136 张图像,其中原始图像和增强后的图像比例为 1:11,在这组原始和增强后的图像中,均存在输送带各种缺陷。增强部分如图 4 所示。

2.2 数据集的标注

由于输送带的划伤和撕裂存在长短不一的尺寸变化,




图 4 部分数据增强图像
Fig. 4 Partial data enhanced image

而现有文献中对不同尺寸目标标注方法缺乏统一标准,这可能会影响后续模型的性能和泛化能力。为了确保模型

性能的稳定性和泛化能力,将使用 Labelimg 软件对同一组数据,分别采用 3 种不同尺寸的标注框,如图 5 所示。




图 5 数据集的 3 种标注方法
Fig. 5 Three labeling methods of data sets

2.3 数据集划分

将原始图像增强后,对得到的 5 136 张输送带图像完成标注,再将数据集划分为 3 个主要类别:撕裂、磨损、破

洞。数据集按照 8:2 的比例分为训练集和验证集,既从数据集中随机抽取 4 109 张图片作为训练集,用于模型拟合和神经网络参数的训练,剩余 1 027 张图片作验证集,用于

调整模型的超参数,并对模型能力展开初步的评估。

3 改进 YOLOv5 网络模型

3.1 特征提取改进

在 FeatureGet 网络中,原有的 C3 模块起到了增加网络深度和感受野,提高特征提取能力的作用。为了进一步提升网络性能,决定设计一个新的模块 C3A(如图 6 所示)来替换 Backbone 中的 C3_1、C3_2、C3_3 模块(如图 7 所示)。

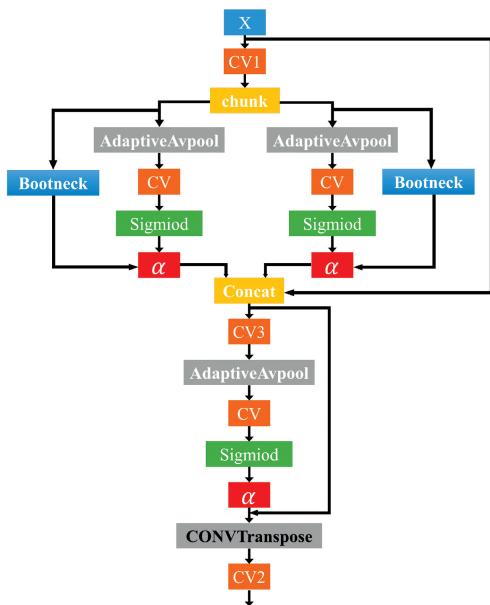


图 6 C3A 模块

Fig. 6 C3A module

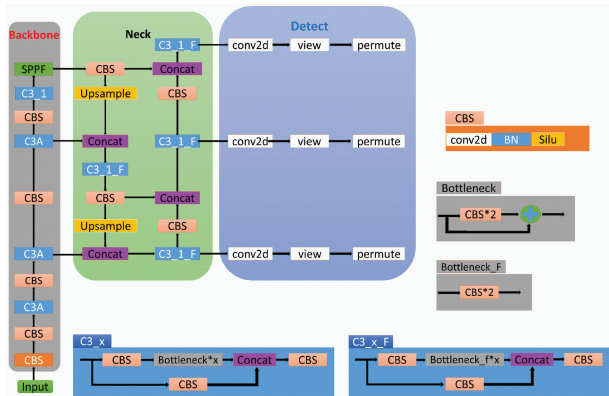


图 7 特征提取改进

Fig. 7 Improvement of feature extraction

在 C3A 改进中,首先,对来自上一层特征的 X 进行卷积处理,通过 chunk 的操作将其分割成两部分,这两部分特征图具有不同通道。使得网络能够探索和利用不同通道上的特征信息,有效增加特征表达的丰富性。接着,两部分特征图分别进行 AdaptiveAvgPool (APL) 处理,降低特征图的分辨率并提取全局特征,以获得全局上下文信

息。之后,对经过 APL 处理后的特征图进行卷积,并使用 Sigmoid 函数归一化,得到每个通道上的权重信息。这一步类似于注意力机制,为每个通道分配权重,从而突出重要特征的重要性。分割的特征图经过 Boot neck 提取特征,并与之前得到的权重信息相乘,为每个数值在通道上附加一个权重,增强重要特征影响的同时,并抑制了不重要的特征。

接下来,将得到的特征与原始输入通过 Concat 拼接,原始输入作为较大的残差边,有助于信息流的稳定传递。随后,进行卷积操作并调整通道数,宽高减半以增加感受野。拼接后特征图通道数增加,注意力机制能够从更多特征中筛选出重要的特征。为进一步筛选,网络又进行一次 APL-CV-Sigmoid 流程,进一步增强注意力机制,并与拼接后的特征相乘。最后,使用 CONVTranspose 反卷积将特征图的大小恢复,并通过一次卷积调整通道数。不仅恢复特征图的大小,还通过通道调整增强了特征的表达能力。

在 C3A 模块中,首先通过为每个通道分配权重,模块实现了动态调整特征图重要性的能力,显著增强了网络对关键信息的敏感度;其次,引入 APL-CV-Sigmoid 流程以实现特征图的注意力机制,有效提升了网络筛选重要特征的能力;最后,通过特征分割、拼接和反卷积操作,模块不仅增强了特征的表达力,还促进了不同特征之间的信息融合。这些设计共同作用,显著提升了 FeatureGet 网络在特征提取和决策过程中的性能,极大地增强了网络的整体学习能力。

3.2 特征融合改进

在 YOLOv5 的网络结构图中,Backbone 负责提取图像最原始的特征信息。尽管 Backbone 与 Neck 的 feature pyramid network(FPN)结构有直接对接,但可能会导致原始信息出现丢失,特别是边缘和纹理信息。

为解决这一问题,在 Backbone 与 FPN、FPN 与 path aggregation network(PAN)交互的基础上,引入 PAN 与 Backbone 直接交互。让 PAN 能够得到更多原始图像特征信息,增加输出与原始的直接关系,为特征信息提供了更多传递路径。具体来说,将 C3_2 位置的输出进行简单卷积操作,缩减特征图的宽和高。并与 PAN 结构的 Concat 进行拼接,确保两个特征图在空间维度上对齐,有效保留了原始特征信息,避免在特征金字塔构建过程中可能的信息丢失。对后续拼接位置的输出也采取类似的方法。

通过短接(short circuit,SC)的方式,可充分保留更多的原始特征信息送入 Detect 中。改进增强特征融合过程的多样性,使模型能更好地融合原始特征信息,提高了特征融合的效果,有助于提升模型的检测精度。具体改进过程如图 8 所示。

3.3 损失函数改进

原始的损失函数 bbox_iou 用于回归目标框,通过计算网络预测的目标框与真实目标框的交并比(iou)来衡量重

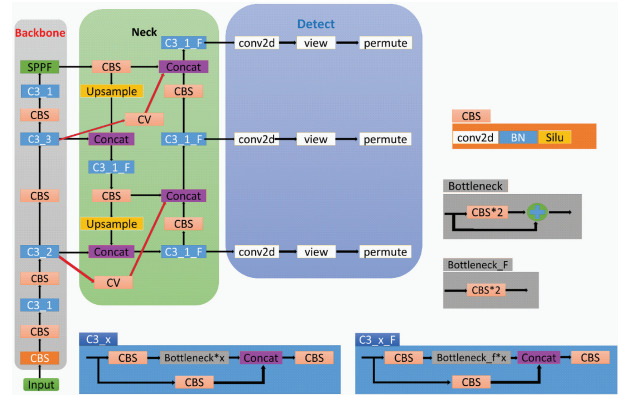


图 8 特征融合改进

Fig. 8 Improved feature fusion

叠程度。当 $oiou$ 值越接近 1,说明预测框与真实框越接近,损失函数的值越小。在目标检测任务中,最小化损失函数是使预测框与真实框接近的关键。为进一步优化 $bbox$ 回归,在原始 $oiou$ 的基础上,融入微调后的交并比 (fine-tuned iou , $fiou$),并定义 2 个参数 d 、 u ,用于设置 $oiou$ 值的上下限,默认值为 0.00、0.95。具体计算过程如下:

$$fiou = \frac{oiou - d}{u - d} \quad (1)$$

$$fiou = \max(0, \min(1, fiou)) \quad (2)$$

$$fiou = \frac{oiou - d}{u - d}, oiou < u \quad (3)$$

$$fiou = 1, oiou \geq u \quad (4)$$

$$Lfocaler = \text{mean}(oiou - fiou) \quad (5)$$

$$Lbox = Lfocaler + Lbox \quad (6)$$

式中: $oiou$ 表示原始的 $bbox_iou$ 损失; $fiou$ 是对 $oiou$ 的缩放; $Lfocaler$ 表示根据 $oiou$ 大小进行线性调整的损失项; $Lbox$ 是最终的损失函数。

改进的目的是在不断优化目标检测网络中边界框 ($bbox$) 的回归过程,通过引入 $fiou$,能够更好的反映预测框与真实框之间的距离,特别是在 $oiou$ 值较低时,能够提供更强的惩罚,从而引导模型学习更加精确的边界框。此

外,对 $oiou$ 进行缩放和裁剪,确保其值被限制在 0~1 之间,这样损失函数能够更好地约束模型预测的 $bbox$ 与真实 $bbox$ 之间的位置关系,避免过拟合或欠拟合。通过线性调整 $oiou$ 损失,模型能够更灵活地处理不同难度的样本,特别是在 $oiou$ 值接近阈值时。这种改进有助于提高目标检测模型的精度,特别是在处理重叠度不高的边界框,有效降低误检,漏检情况。

4 实验结果与分析

4.1 实验环境及参数设置

本文实验操作系统为 Windows10,CPU 型号为 Intel (R) Core (TM) i5-12400F,GPU 型号为 NVIDIA RTX 4070Ti,使用语言为 Python,实验平台深度学习框架为 Pytorch-1.10.0/CUDA10.2。本文算法初始化训练参数为:batch_size 大小为 8,学习率为 0.01,epoch 为 120。

4.2 评价指标

实验采用精确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP) 等作为评价标准来评估网络的整体性能。其中 P、R、mAP 的计算公式如式 (7)~(9) 所示。

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

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

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P dr(i) \quad (9)$$

式中: TP 表示正确预测为正类样本的数量; FP 表示错误预测为正类样本的数量,即误检的数量; FN 表示错误预测为负类样本的数量,即漏检的数量; n 是数据集中的种类数。

4.3 实验结果与分析

为验证标注框尺寸对实验结果的影响,本文对同一组数据,分别采用 3 种不同的标注框尺寸。采用单一变量控制法,以确保实验的准确性,为后续的消融实验和对比实验提供较为高质量的数据集。结果如表 1 所示。

表 1 不同标注框尺寸的对照

Table 1 Comparison of different box sizes

标注框	Tear	Scratch	Hole	mAP@0.5	P	R
小	0.793	0.769	0.841 0	0.801	0.933	0.93
中	0.939	0.922	0.893 3	0.918	0.980	0.96
大	0.984	0.970	0.949 0	0.967	0.996	0.98

根据表 1 实验结果可知,完整覆盖输送带损伤部分的标注框能够提供更佳检测结果。具体来说,较大的标注框能够更准确地捕捉到损伤区域,而较小的标注框则会导致检测效果下降。如图 9 所示,通过对小、中、大标注框的识别效果进行对比分析,可直观看到不同标注框尺寸对检

测结果的影响。其中小标注框容易导致标注重叠和数据遮挡,影响识别结果的查看和后续改进。虽然中标注框在一定程度上减少了重叠现象,但其识别精度仍不及大标注框。相比之下,大标注框在识别精度和减少遮挡方面表现最佳。因此,后续的消融实验和对比实验将基于大标注框

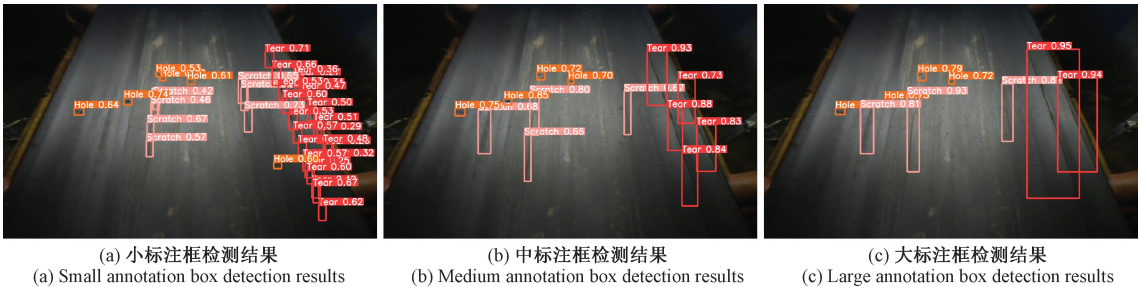


图 9 3 种标注方法的检测效果

Fig. 9 The detection effect of three labeling methods

的数据集进行。

在上述实验中,由于使用预训练模型导致实验结果数值偏高,不利于精确地评估模型在特定任务上的性能,这是因为预训练模型已经学习到了一部分数据特征。因此,为准确评估模型潜力,对比和消融实验中避免使用预训练模型,以利于针对优化和改进。

在对比实验中,使用同一数据集对表 2 中的 4 种目标检测算法进行训练,以验证改进后算法的优越性,具体实

验结果如下。改进后的输送带撕裂检测精度与 YOLOv5、YOLOv3^[24]、Faster-RCNN 相比分别提升了 0.4%、22.7%、8.5%。表面磨损检测精度分别提升了 1.7%、25%、24.3%。破洞检测分别精度提升了 5.1%、21.2%、26.6%。平均精度均值分别提升了 2.4%、23%、19.7%。本文算法相较于其他算法,通过各项数据的对比,具有更高的检测精度,使其输送带缺陷检测结果更加准确,满足工业要求。

表 2 不同模型对比

Table 2 Comparison of different models

模型	Tear	Scratch	Hole	mAP@0.5	P	R
YOLOv5	0.961	0.925	0.685	0.857	0.859	0.856
YOLOv3	0.738	0.692	0.524	0.651	0.988	0.815
Faster-RCNN	0.880	0.700	0.470	0.684	0.843	0.854
改进的 YOLOv5	0.965	0.942	0.736	0.881	0.880	0.865

通过表 3 中的消融实验结果可知,本文所提出的改进可以有效增强原模型的检测效果。其中输送带的撕裂、表面磨损和破洞的检测精度分别达到 96.5%、94.2%、

73.6%,与原始算法相比 mAP 值提升了 2.4%、P 提升了 2.1%、R 提升了 0.9%。

表 3 消融实验结果

Table 3 Ablation experiment results

模型	Tear	Scratch	Hole	mAP@0.5	P	R
YOLOv5	0.961	0.925	0.685	0.857	0.859	0.856
YOLOv5+C3A	0.964	0.937	0.704	0.868	0.874	0.855
YOLOv5+C3A+SC	0.961	0.940	0.720	0.874	0.877	0.860
YOLOv5+C3A+SC+FIOU	0.965	0.942	0.736	0.881	0.880	0.865

5 结 论

根据输送带缺陷的特点,本文对 YOLOv5 进行相应的改进,首先,增强与扩充现有数据,并对输送带的撕裂和损伤进行 3 种不同尺寸的标注。实验结果表明,标注框完整地覆盖,检测的结果最佳。

通过对目标检测网络进行多维度优化,实现显著的性能提升。首先在特征提取阶段,引入类似注意力机制的

C3_A 模块来替换 Backbone 中的 C3_1、C3_2、C3_3 模块,使网络能够更有效地聚焦于对结果有积极影响的特征,提高整体性能;其次,在特征融合原有基础上,采用短接方式使 PAN 与 Backbone 直接进行交互,让 PAN 能够得到更多原始图像特征信息,增加输出特征与原始图像特征的直接关系,减少特征信息丢失;最后,在损失函数上通过引入新的交并比,并设置两个参数,对 *oiou* 进行缩放和裁剪,使其值在 0~1 之间,有效约束模型预测的 bbox 与真实 bbox

之间的位置关系,进一步提升模型对边界框回归的准确性。这些改进使模型在特征提取、特征融合以及损失函数优化方面均取得了突破,显著提高目标检测的效率和精度。

改进的 YOLOv5 检测算法,通过实验结果证明,使输送带缺陷的检测精度有效提高。下一步的工作是通过使用轻量化网络,减少模型参数量和计算量,以提高模型的检测速度,并且保证检测的精度不降。

参考文献

- [1] 张安宁,孙宇坤,尹中会. 带式输送机防纵撕保护研究现状及趋势[J]. 煤炭科学技术, 2007(12): 77-79.
ZHANG AN N, SUN Y K, YIN ZH H. Research status and tendency of longitude tearing protection for belt conveyor[J]. Coal Science and Technology, 2007(12): 77-79.
- [2] CHE J, QIAO T, YANG Y, et al. Longitudinal tear detection method of conveyor belt based on audio-visual fusion[J]. Measurement, 2021, 176: 109152.
- [3] 曹成,金林,赵娜娜. 矿用带式输送机纵向撕裂检测方法研究[J]. 煤炭工程, 2010(2): 85-86,89.
CAO CH, JIN L, ZHAO N N. Research on detection of longitudinal tear on mine conveyor belt[J]. Coal Engineering, 2010(2): 85-86,89.
- [4] 王瑞义,韩菊娣. 胶带纵向撕裂保护装置[J]. 煤矿自动化, 1992(3): 42-45.
WANG R Y, HAN J D. Belt longitudinal tear protection device[J]. Coal Mine Automation, 1992(3): 42-45.
- [5] 游春霞,张申. 新型输送带纵向撕带监测系统的设计[J]. 煤炭科学技术, 2010, 38(8): 89-92,96.
YOU CH X, ZHANG SH. Design on new monitoring and measuring system of conveyor belt longitudinal tearing [J]. Coal Science and Technology, 2010, 38(8): 89-92,96.
- [6] 杨庆宏,张安宁,陶选. 带式输送机输送带纵向撕裂保护装置的研究[J]. 煤矿机械, 2006(7): 139-140.
YANG Q H, ZHANG AN N, TAO X. Research on protector for monitor longitudinal rip of belt conveyor[J]. Coal Mine Machinery, 2006(7): 139-140.
- [7] 王广丰,钟海娜. 输送机胶带纵向撕裂防护与监测[J]. 矿山机械, 2005(8): 73-75.
WANG G F, ZHONG H N. Protection and monitoring of belt conveyors' belt lengthwise fracture [J]. Mining Machinery, 2005(8): 73-75.
- [8] 童敏明,汪博,蒋昌龙,等. 新型矿井输送机输送带纵向撕裂检测方法[J]. 煤矿机械, 2013, 34(10): 191-193.
TONG M M, WANG B, JIANG CH L, et al. New detection method for longitudinal tear of conveyor belt in coal mine[J]. Coal Mine Machinery, 2013, 34(10): 191-193.
- [9] 荣锋,苗长云,徐伟. 强力输送带 X 光无损检测仪的研制[J]. 光学精密工程, 2011, 19(10): 2393-2401.
RONG F, MIAO CH Y, XU W. Development of non-destructive tester for steel cord conveyor belts [J]. Optics and Precision Engineering, 2011, 19(10): 2393-2401.
- [10] YANG Y, MIAO C, LI X, et al. On-line conveyor belts inspection based on machine vision[J]. Optik, 2014, 125(19): 5803-5807.
- [11] 徐辉,刘丽静,沈科,等. 基于多道线性激光的带式输送机纵向撕裂检测[J]. 工矿自动化, 2021, 47(7): 37-44.
XU H, LIU L J, SHEN K, et al. Longitudinal tear detection of belt conveyor based on multi linear lasers[J]. Industrial and Mining Automation, 2021, 47(7): 37-44.
- [12] 李海滨,张春明,张元正,等. 线激光辅助的皮带撕裂视觉检测方法[J]. 光学技术, 2011, 37(4): 466-470.
LI H B, ZHANG CH M, ZHANG Y ZH, et al. A new inspection method for rip of conveyor belt based on line laser stripe [J]. Optics Technology, 2011, 37(4): 466-470.
- [13] 王晓超,乔铁柱. 基于 Hough 变换的输送带纵向撕裂检测方法[J]. 工矿自动化, 2015, 41(12): 68-70.
WANG X CH, QIAO T ZH. Detection method of conveyor belt longitudinal tear based on hough transform [J]. Industrial and Mining Automation, 2015, 41(12): 68-70.
- [14] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [15] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [16] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Computer Vision-ECCV 2016: 14th European Conference, 2016: 21-37.
- [17] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [18] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1): 198-219.
ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Journal of Instrumentation, 2022, 43(1): 198-219.

[19] 张梦超,周满山,张媛,等. 基于深度学习的矿用输送带损伤检测方法[J]. 工矿自动化, 2021, 47(6): 51-56.
ZHANG M CH, ZHOU M SH, ZHANG Y, et al. Damage detection method for mine conveyor belt based on deep learning [J]. Industrial and Mining Automation, 2021, 47(6): 51-56.

[20] 周宇杰,徐善永,黄友锐,等. 基于改进 YOLOv4 的输送带损伤检测方法[J]. 工矿自动化, 2021, 47(11): 61-65.
ZHOU Y J, XU SH Y, HUANG Y R, et al. Conveyor belt damage detection method based on improved YOLOv4 [J]. Industrial and Mining Automation, 2021, 47(11): 61-65.

[21] 薄景文,张春堂,樊春玲,等. 改进 YOLOv3 的矿石输送带杂物检测方法[J]. 计算机工程与应用, 2021, 57(21): 248-255.
BO J W, ZHANG CH T, FAN CH L, et al. Ore conveyor belt sundries detection based on improved YOLOv3[J]. Computer Engineering and Applications, 2021, 57(21): 248-255.

[22] MAHENDRAKAR T, WHITE R T, WILDE M, et al. Real-time satellite component recognition with YOLO-V5[C]. Small Satellite Conference, 2021.

[23] 陶显,侯伟,徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
TAO X, HOU W, XU D. A survey of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.

[24] JOCHER G, STOKEN A, BOROVEC J, et al. Ultralytics/YOLOv5: v3. 1-bug fixes and performance improvements[J]. Zenodo, 2020, DOI: 10. 5281/ZENODO. 4154370.

作者简介

张宏飞,硕士研究生,主要研究方向为智能装备。
E-mail:2419895499@qq. com

冯永利(通信作者),博士,讲师,主要研究方向为机器人技术。
E-mail:fengyongli@ncst. edu. cn