

## 融合注意力机制与线激光辅助的输送带缺陷检测网络

宋震, 王纪强, 侯墨语, 赵林

### 引用本文

宋震, 王纪强, 侯墨语, 赵林. 融合注意力机制与线激光辅助的输送带缺陷检测网络[J]. 计算机科学, 2024, 51(6A): 230800115-6.

SONG Zhen, WANG Jiqiang, HOU Moyu, ZHAO Lin. Conveyor Belt Defect Detection Network Combining Attention Mechanism with Line Laser Assistance [J]. Computer Science, 2024, 51(6A): 230800115-6.

---

### 相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [面向产线AI质检的少样本评测方法研究和验证](#)

Study and Verification on Few-shot Evaluation Methods for AI-based Quality Inspection in Production Lines

计算机科学, 2024, 51(6A): 230700086-8. <https://doi.org/10.11896/jsjcx.230700086>

#### [基于BERT和CNN的药物不良反应个案报道文献分类方法](#)

Literature Classification of Individual Reports of Adverse Drug Reactions Based on BERT and CNN

计算机科学, 2024, 51(6A): 230400049-6. <https://doi.org/10.11896/jsjcx.230400049>

#### [DUWe:动态未知词嵌入方法在Web异常检测中的应用](#)

DUWe:Dynamic Unknown Word Embedding Approach for Web Anomaly Detection

计算机科学, 2024, 51(6A): 230300191-5. <https://doi.org/10.11896/jsjcx.230300191>

#### [WiCare:一种非接触式的老人如厕跌倒监测模型](#)

WiCare:Non-contact Fall Monitoring Model for Elderly in Toilet

计算机科学, 2024, 51(6A): 230700044-8. <https://doi.org/10.11896/jsjcx.230700044>

#### [深度学习驱动下IaaS云运维异常检测算法的研究进展](#)

Research Progress of Anomaly Detection in IaaS Cloud Operation Driven by Deep Learning

计算机科学, 2024, 51(6A): 230400016-8. <https://doi.org/10.11896/jsjcx.230400016>

# 融合注意力机制与线激光辅助的输送带缺陷检测网络

宋震 王纪强 侯墨语 赵林

齐鲁工业大学(山东省科学院),山东省科学院激光研究所 济南 250104

(sz\_bigdreamer@163.com)

**摘要** 针对输送带缺陷种类繁多、缺陷特征像素占比小以及传统算法检测精度低的问题,采用随机仿射变换,扩充样本数据集;分析各通道间的关联关系及其贡献值对模型特征提取的影响,提出了一种通道关联加权注意力机制,利用关联卷积及全连接方式计算通道关联度及贡献权值,调整相应通道信息占比,提升模型检测精度;分析了上采样以及卷积块对输出特征图大小的影响,改进原特征金字塔特征卷积块及上采样结构,提高算法对小目标的特征提取以及缺陷检测能力;最后在输送带缺陷数据集上进行测试。结果表明:改进算法模型能对输送带典型的异物插入、破损、撕裂等缺陷特征进行有效识别,识别精准度可达99.7%,召回率大于99.5%,平均精度均值达到99.5%。

**关键词:** 皮带缺陷检测;深度学习;通道关联加权处理;小目标检测层

**中图分类号** TP399

## Conveyor Belt Defect Detection Network Combining Attention Mechanism with Line Laser Assistance

SONG Zhen, WANG Jiqiang, HOU Moyu and ZHAO Lin

Laser Institute, Qilu University of Technology(Shandong Academy of Sciences), Jinan 250104, China

**Abstract** Aiming to the problems of a wide variety of conveyor belt defects, a small proportion of defect feature pixels, and the low detection accuracy of traditional algorithms, random affine transformation is used to expand the sample dataset. The influence of the correlation between each channel and its contribution value on the model feature extraction is analyzed, and a channel correlation weighted attention mechanism is proposed. The correlation degree and contribution weight of each channel are calculated by correlation convolution and full connection, and the proportion of corresponding channel information is adjusted to improve the detection accuracy of the model. The influence of upsampling and convolution block on the size of the output feature map is analyzed. The original feature pyramid feature convolution block and upsampling structure are improved to enhance the feature extraction and defect detection ability of the algorithm for small targets. Finally, the test is conducted on the conveyor belt defect data set. The results show that the improved algorithm model can effectively identify the typical defect features such as foreign body insertion, breakage, and tearing of the conveyor belt. The recognition precision can reach 99.7%, the recall rate is increased to 99.5%, and the mean average precision is 99.5%.

**Keywords** Belt defect detection, Deep learning, Channel association weighting, Small target detection layer

### 1 引言

皮带运输机被广泛应用于煤炭转运、矿石开采以及物流运输等领域<sup>[1-3]</sup>。输送带作为运输机的核心部件,造价占整个运输机总额的50%以上,同时,皮带运输机在运行过程中受钎杆、尖石等尖锐利物冲击及老化破损等因素的影响,输送带纵向撕裂事故时有发生,如不能及时发现并采取有效措施,将造成大面积的输送带撕裂事故,给企业造成严重的经济损失,甚至会导致人员伤亡<sup>[4-7]</sup>。因此,研究输送带的实时精准检测对于降低企业损失、减少人员伤亡都具有重要意义。

目前的输送带缺陷检测方法大致分为接触式与非接触式检测两种。接触式检测主要是将传感器置于输送带下方,通过对刺破物掉落质量的感应或者对传感器的触碰实现检测,如棒性检测、漏料检测、压力检测以及电磁感应检测等<sup>[8-10]</sup>。

在上述检测方法中,由于刺破物长度不足或者输送带振动等,易出现漏报、误报等现象。非接触式检测方法大多采用人工智能与视觉检测技术相结合的方式进行检测。但受外界自然光、粉尘、皮带面凹凸不平等因素的影响,缺陷特征识别准确率较低,无法满足实际工程应用。

随着大数据集的应用及硬件系统的发展,基于深度学习的检测方法成为缺陷分析的主流,目前被广泛应用于道路破损、织物缺陷以及钢轨焊点检测等领域。而针对输送带的缺陷检测,也提出了深度学习+线激光的检测方案。图1给出了当输送带出现不同缺陷时,激光线对应的缺陷特征图像。其主要检测难点如下:1)输送带缺陷图像样本较少,模型对缺陷特征感知不足,模型难以拟合;2)现有模型无法提供针对激光轮廓线变化提高模型识别能力的解决方案,检测精度较低;3)缺陷关键像素点占用有效像素少,导致现有模型对小目标

基金项目:国家重点研发计划(2022YFB3207602);山东省自然科学基金重点项目(ZR2020KC012)

This work was supported by the National Key Research and Development Program of China(2022YFB3207602) and Key Project of Shandong Provincial Natural Science Foundation(ZR2020KC012).

通信作者:赵林(linzhao1225@126.com)

缺陷检测模块的缺失,易引起系统漏报。




图1 数据集样本示例  
Fig. 1 Examples of dataset

针对上述难点,结合输送带不同缺陷特征差异,本文提出了一种融合注意力机制与激光辅助的输送带缺陷检测网络。该方法的主要贡献如下:

1) 针对皮带缺陷样本少且缺陷感知不足的弊端,自建 24483 张输送带缺陷样本数据集,并提出一种仿射变换图像增强方法,通过扩充数据集样本及加强缺陷分类识别,有效提高算法的泛化能力。

2) 利用卷积神经网络将特征图拆分为多层特征通道,将通道加权处理后融合检测网络,利用通道对特征层贡献值的差异,分别赋予不同的权重系数,提升模型中重要通道参数的占比,实现对缺陷特征的精准识别,提高模型检测精度。

3) 针对皮带缺陷区域包括的像素点在整张图中占比较少的特点,构建小目标检测模块,利用特征金字塔对特征层上采样,扩大特征层,提升模型对小目标的缺陷检测能力。

## 2 相关工作

初期对输送带的检测研究采用传统视觉图像技术来对皮带缺陷进行检测。Zhao 利用出现缺陷时图像灰度值的变化差异,通过灰度和中值滤波算法进行检测,经测试,超过 180 mm 的撕裂均能得到有效识别,但其缺乏对其他类型缺陷的检测,泛化能力弱,且没有针对小尺寸缺陷提出解决方案,不适用于小缺陷的检测<sup>[11]</sup>。Hu 等利用灰度最小二乘支持向量机算法,通过图像灰度的变化进行判断,该方法对缺陷目标

有较好的识别度,但检测精度不高,仅能达到 91% 缺陷识别率<sup>[12]</sup>。Miao 等利用输送带发生撕裂时声音的差异对输送带进行缺陷检测,模型能更积极地处理异常状态,但由于现场振动及环境噪声的干扰,误报率较高<sup>[13]</sup>。

深度学习技术的发展为输送带缺陷检测提供了一种新的技术手段。目前的深度学习目标检测模型主要分为单阶段模型(SSD, YOLOv4, YOLOv5 等)和双阶段模型(RCNN, Mask-RCNN 等),由于单阶段模型具有检测速度快、检测精度高等优势,其应用更为广泛<sup>[14-18]</sup>。Sheng 等提出了一种改进的区域卷积神经网络输送带检测方法,利用大尺度卷积扩大网络感受野,提高对微小破损的检测效果,但网络训练缺陷类型单一,模型缺乏泛化能力<sup>[19]</sup>。Hao 等通过在 YOLO 网络中融合卷积块注意力模型,实现对输送带插入异物的检测,但由于训练过程中没有关注小尺寸异物的缺陷特征,对小尺寸缺陷的检测精度较低<sup>[20]</sup>。

## 3 输送带缺陷检测网络

针对上述方法的不足,本文提出了一种融合注意力机制同时增加小目标检测层的输送带缺陷检测模型,其主要基于 YOLOv5s 检测网络(包含 Backbone 网络、Neck 网络和 Prediction 网络),由于原神经网络对特征关注较为发散,致使模型对缺陷特征的感知力不足,同时对缺陷特征像素占比小的小目标检测精度较弱。基于上述原因,通过对图片数据增强、通道关联加权处理及小目标特征提取增强,提出了一种高灵敏度、有针对性的输送带缺陷检测网络。网络模型主要是在输入前通过随机仿射变换数据增强模块(Random Affine Transform Data Enhancement, RATDE)扩充样本数据集,提升模型的泛化能力;在主干网络与 Neck 网络之间增加注意力增强模块(Association & Weighting, Awnet),增加特定通道中的信息占比;同时通过增加 CSP 等模块,增强模型上采样能力,以此改进特征金字塔结构,增加小目标检测网络,以实现各类缺陷的有效检测以及对小目标的精准识别。改进后的整体网络模型如图 2 所示。

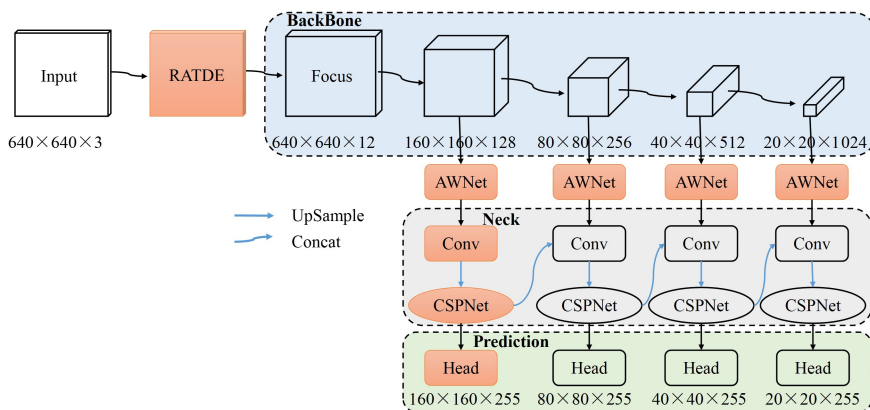


图2 改进后网络图

Fig. 2 Diagram of improved network

### 3.1 随机仿射变换样本扩充

由于目前 YOLO 网络采用的数据增强 Mosaic 方法对图像进行裁剪缩放后,组合的新图有可能裁剪掉激光线条关键区域,造成神经网络特征提取障碍,从而导致模型的识别准确率下降。根据输送带缺陷激光线条特征变化规律,在主干网络

之前添加随机仿射变换数据增强模块(RATDE),通过对输入图片进行仿射变换,利用生成随机数作为仿射变换数值,对样本进行旋转、平移、投影等操作以扩充样本,有效避免了 Mosaic 对图像裁剪缩放造成的图像信息丢失,实现了在不丢失激光线条信息的前提下对数据集进行扩充。其可表述为:

$$x' = g(R(x)) \quad (1)$$

其中,  $x$  为输入图像,  $g(x)$  为仿射变换矩阵,  $R(x)$  为随机函数。图 3 为仿射变换后的部分图像。




图 3 仿射变换示例图

Fig. 3 Example of affine transformation

### 3.2 通道关联加权处理

主干网络在进行多次深层卷积后,部分特征信息会丢失,并且每次卷积后通道间的关联信息利用率低,为此提出了一种针对输送带缺陷的通道关联加权注意力机制(AWNet),结构如图 4 所示。




图 4 注意力机制示意图

Fig. 4 Attention mechanism diagram

对输入的  $H \times W \times C$  特征层  $F$  取该通道全局平均值,获得  $1 \times 1 \times C$  空间特征块  $Z$ ,其可表示为:

$$Z = GAP = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (2)$$

获得的空间特征块做两个分支运算,对第一分支特征通道进行一维卷积,卷积核大小与通道数成正比,其可表述为:

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (3)$$

其中,  $b=1, \gamma=2, C$  为通道数,对每个通道与其相邻的  $k$  个通道进行卷积,实现局部跨通道交互,增强通道之间的关联性。

对第二分支的通道特征样本利用全连接模块学习样本信息,激活特定的样本,学习过程可以表述为式(4)。使用两个不同的全连接层实现对参数的控制,即  $W_1$  做降维全连接学习,降维比为 16,将学习结果使用 RELU 函数激活,  $W_2$  做升维全连接学习,实现通道数的整合,学习结果相乘后输出。

将两特征分支输出逐通道相加,并使用 sigmoid 函数有选择地强调信息特征,其公式为式(5),注意力实现通道关联加权整合全过程可表述为式(6)。

$$g(Z, W) = W_2 \delta(W_1 Z) \quad (4)$$

$$\sigma(x) = \frac{1}{(1 + e^{-x})} \quad (5)$$

$$F(Z, W) = \sigma(\text{Conv1d}(Z, k) + g(Z, W)) \quad (6)$$

最后将学习结果输出,通过乘法运算将结果逐项加权到相应特征通道上,使得神经网络重点关注与激光线条相关的特征通道,抑制对当前任务相关性不强的通道,同时通道间的关联性得到增强。经过注意力机制后,模型更加注重与输送带各类缺陷相关性强的通道特征提取,抑制贡献较低通道的活跃程度,从而提升模型的整体检测效果。

### 3.3 小目标特征提取

由于输送带缺陷区域所覆盖像素点在整张图片中占比较少,属于小目标检测,而原网络经两次上采样后所得特征图大小为  $80 \times 80$ ,不能满足发生缺陷时激光线的变化检测。针对输送带缺陷数据样本的特殊性,分析上采样以及卷积等模块的关系后,在原有 3 个检测层基础上构建针对小目标的缺陷检测模块,如图 5 所示。对 Neck 网络顶层输出的  $80 \times 80$  的特征层作特征提取卷积和上采样操作,使得特征图扩大到  $160 \times 160$ ,采集该特征层特征后,进行降采样,并将获取的特征图与主干网络上层特征层融合,以此获取更大的特征空间,用于对小目标进行检测,同时将融合结果输出作为新增的小目标检测层,用于检测  $4 \times 4$  以上的目标,弥补原有检测层在小目标缺陷检测能力方面的不足。




图 5 YOLO-ARS 网络结构图

Fig. 5 YOLO-ARS network structure diagram

## 4 实验及结果分析

### 4.1 实验参数与数据集

本文实验平台为 Windows10 系统、i5-12490F 3.00GHZ 处理器以及 NVIDIA RTX3060-12GB 环境,实验开发环境为 Python3.8.2,输送带缺陷检测模型由 Pytorch1.11.0 深度学习框架构建,加速程序为 CUDA11.3.1。

本文实验参数如表 1 所列,实验平台如图 6 所示。

表 1 实验参数

Table 1 Experimental parameters

Type	Parameter
Input	[640, 640]
Epoch	100
batch size	16
learn rate	$1 \times 10^{-3}$
Optimizer	SGD




图 6 皮带实验平台

Fig. 6 Belt experimental platform

实验数据集为自建输送带缺陷激光线数据集,通过如图6所示的设备模拟皮带运输机现场工作环境,对3种缺陷类型图像共采集24483张,其中包含异物插入图像5436张、破损图像2300张,撕裂图像5656张,正常图像11091张,通过Labelimg工具对上述图像中缺陷位置进行标注,得到与图像对应的yaml文件,作为训练过程中所需关键点信息送入模型。

## 4.2 评估指标

在实验中使用3个指标,分别为精准度(Precision,  $P$ )、平均精度均值(mean Average Precision,  $mAP$ )和召回率(Recall,  $R$ )。

计算公式如下:

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


$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (8)$$

$$R = \frac{TP}{TP + FN} \quad (9)$$


以撕裂缺陷为例,  $TP$  为正确检测出该缺陷为撕裂的数量,  $FP$  为错误检测为撕裂的数量,  $FN$  为没有检测为撕裂的数量,  $AP_i$  为第  $i$  类平均精度,  $N$  为类别数量。

## 4.3 消融实验

模型中分别加入 RATDE, AWNet 以及小目标检测层 (Small Target) 后在验证集上对模型性能指标进行验证, 观察改进后的模型与原模型的性能指标变化。根据表 2 可以发现, RATDE 的加入使得数据集中正负样本的数量增加, 精准度提升了 0.2%, 召回率提升到 97.5%; 模型添加 AWNet 与小目标检测层后使得模型的精准度分别提升了 2.3% 和 0.8%, 召回率分别提升 1.2% 和 0.9%, 平均精度均值分别提升了 2.3% 和 1.2%。模型经过整体改进后对特征感知更为明显, 对小尺寸特征提取更加深入, 精准度可达 99.7%, 召回率提升至 99.5%, 平均精度均值提升了 3.3%。同时, 通过对改进前后的模型精准度和召回率进行对比, 由图 7 可以发现, 经过 100 轮迭代后, 改进后模型与原始 YOLO 相比精确率和召回率均有明显提升。



(a) 精确率



(b) 召回率

图7 精确率和召回率变化曲线


Fig. 7 Change curves of precision and recall

表2 测试集增强模块指标变化


Table 2 Performance enhancement module indicators change on test set

Method	RATDE	AWNet	Small Target	$P$	$R$	$mAP$
YOLO +	×	×	×	0.961	0.969	0.962
	√	×	×	0.963	0.975	0.965
	×	√	×	0.984	0.981	0.985
	×	×	√	0.969	0.978	0.974
	√	√	×	0.976	0.981	0.975
	×	√	√	0.991	0.986	0.981
YOLO-ARS	√	×	√	0.986	0.982	0.979
	√	√	√	0.997	0.995	0.995


为了更好地观察模型注意力的分布, 利用 Grad-CAM 工具对加入注意力机制前后对模型进行可视化。通过图 8 可以发现, AWNet 加入前, 神经网络关注点较为离散, 加入后, 神经网络根据特征区域中通道的权重变化调整关注度, 神经网络对激光线条的关注点聚焦在激光线周围, 对特征的提取更能反映激光轮廓线的变化。



(a) 原图



(b) AWNet 加入前



(c) AWNet 加入后

图8 神经网络加入 AWNet 前后对比

Fig. 8 Comparison of neural network before and after adding AWNet

## 4.4 实验测试分析

### 4.4.1 损失函数收敛性测试

对改进后的模型 YOLO-ARS(AWNet & RATDE & Small target) 和 YOLO 在自建输送带缺陷数据集下进行实验, 损失函数结果如图 9 所示。




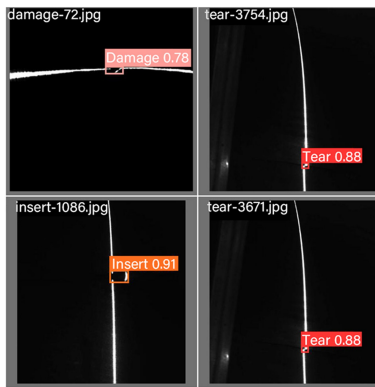
图9 模型损失函数变化图

Fig. 9 Diagram of model loss function change


YOLO-ARS 模型经过 100 轮迭代后,边界框回归损失曲线最终在 0.02112 左右不再继续下降,目标置信度损失在 0.00145 左右趋于平稳,类别损失在 0.00012 左右不再降低。因此改进后模型边界框回归损失和目标置信度损失比原模型更低,尤其是目标置信度损失,收敛效果比 YOLO 更加明显。

4.4.2 缺陷性能测试

YOLO-ARS 在测试集上对撕裂(Tear)、破损(Damage)以及异物插入(Insert) 3 种常见缺陷类型进行测试,结果如表 3 所列。3 种缺陷类型的精准度(P)、召回率(R)以及大于 0.5 的平均精度均值(mAP)均大于 0.995。图 10 给出了不同模型对输送带缺陷数据集的测试结果,其中,类别后数值为置信度,表示模型检测为该类型的概率。由图可以看出,小目标特征检测模块以及注意力机制的加入,使得改进后的模型对各类缺陷尤其是变化不明显的小尺寸缺陷(如撕裂缺陷)的识别概率与改进前模型相比有明显提升。



(a) YOLO



(b) YOLO-ARS

图 10 YOLO 与 YOLO-ARS 在皮带缺陷数据集上测试对比

Fig. 10 Comparison of YOLO and YOLO-ARS on belt defect dataset

表 3 YOLO-ARS 不同缺陷检测性能指标

Table 3 Different defect detection performance metrics of YOLO-ARS

Category	P	R	mAP@0.5
All	0.996	0.996	<b>0.995</b>
Tear	0.997	<b>0.995</b>	0.995
Damage	<b>0.996</b>	0.997	0.995
Insert	0.996	0.996	0.995

**结束语** 本文提出一种改进的 YOLO 输送带缺陷检测方法,针对输送带缺陷数据集的特殊性,使用随机仿射变换对数据集进行增强,同时在主干网络与特征增强网络的连接处添加通道关联加权的注意力机制,根据通道间的联系以及不同通道对特征层贡献度的差异给予其不同的权重,提升模型的特征提取能力。针对输送带缺陷大部分为小目标这一特征,在预测网络中添加针对小目标的检测层,提升小目标检测精度。对模型在自建输送带数据集上进行测试,实验结果表明,针对 3 种常见缺陷,改进后的网络缺陷检测精准度可达 99.7%,召回率大于 99.5%,以及平均精度均值达到 99.5%,可有效实现对输送带常见缺陷的精准检测。

参考文献

- [1] CHE J, QIAO T, YANG Y, et al. Longitudinal tear detection method of conveyor belt based on audio-visual fusion [J]. Measurement, 2021, 176(1): 109152.
- [2] WANG Y, MIAO C, LIU Y, et al. Research on a sound-based method for belt conveyor longitudinal tear detection [J]. Measurement, 2022, 190(1): 110787.
- [3] TOM K, LI J. Heat load estimation of conveyed ore in underground mines [J]. CIM Journal, 2020, 11(2): 155-163.
- [4] MIAO D, WANG Y, YANG L, et al. Foreign Object Detection Method of Conveyor Belt Based on Improved Nanodet [J]. IEEE Access, 2023, 11: 23046-23052.
- [5] HAO X, MENG X, ZHANG Y, et al. Conveyor-Belt Detection of Conditional Deep Convolutional Generative Adversarial Network [J]. CMC—Computer Materials & Continua, 2021(11): 2671-2685.
- [6] ZHANG M, SHI H, ZHANG Y, et al. Deep learning-based damage detection of mining conveyor belt [J]. Measurement, 2021, 175(99): 109130.
- [7] QU D, QIAO T, PANG Y, et al. Research On ADCN Method For Damage Detection Of Mining Conveyor Belt [J]. IEEE Sensors Journal, 2020, 21(6): 8662-8669.
- [8] LI W, LI C, YAN F. Research on belt tear detection algorithm based on multiple sets of laser line assistance [J]. Measurement,

2021,174(2):109047.

- [9] LV Z,ZHANG X,HU J,et al. Visual detection method based on line lasers for the detection of longitudinal tears in conveyor belts [J]. *Measurement*,2021,183(6):109800.
- [10] PATENTINHABER G. Method and display device for displaying a wear dimension of an endless roller link conveyor belt or chain link conveyor belt; DE, DE102020114979B4 [P]. [2022-04-07].
- [11] ZHAO C. On-line Monitoring System for Longitudinal Tear of Conveyor Belt based on Lab-VIEW [C]// *International Conference on Advances in Electrical Engineering and Computer Applications*. 2022.
- [12] HU X,ZONG M. Fault Prediction Method of Belt Conveyor Based on Grey Least Square Support Vector Machine [C]// *International Conference on Measuring Technology and Mechatronics Automation*,2021.
- [13] MIAO D,WANG Y,LI S. Sound-Based Improved DenseNet Conveyor Belt Longitudinal Tear Detection [J]. *IEEE Access*, 2022;123801-123808.
- [14] HE K,GKIOXARI G,DOLLAR P,et al. Mask R-CNN[C]// *IEEE International Conference on Computer Uision (ICCV)*, 2017.
- [15] SUN X H,GU J N,HUANG R. A modified SSD method for Electronic Components Fast Recognition. [J]. *Optik*,2020,205: 163767.
- [16] LI Y,LU Y J,CHEN J. A deep learning approach for real-time rebar counting on the construction site based on YOLOv3 detector. [J]. *Automation in Construction*,2021,124:103602.
- [17] GUO F,QIAN Y,SHI Y F. Real-time railroad track components inspection based on the improved YOLOv4 framework. [J]. *Automation in Construction*,2021,125(3):103596.
- [18] LI C L,XIE G,WANG Y,et al. Defect detection of polaroid based on YOLOv3-Tiny-D algorithm[J]. *Computer Integrated Manufacturing Systems*,2022,28(3):787-797.
- [19] SHENG P F,HAO X L,LYU J L. Conveyor belt tear detection with improved regional convolution neural network[J]. *Computer Engineering And Design*,2023,44(3):908-915
- [20] HAO S,ZHANG X,MA X,et al. Foreign object detection in coal mine conveyor belt based on CBAM-YOLOv5[J]. *Journal of China Coal Society*,2022,47(11):4147-4156.



**SONG Zhen**, born in 1999, postgraduate. His main research interests include defect detection and target recognition.



**ZHAO Lin**, born in 1981, associate research fellow, master's supervisor. His main research interests include optical fiber sensor and laser detection technology.