

DOI:10.3969/j.issn.1003-5060.2023.01.005

基于改进 YOLOv3 的输送带纵向撕裂多视角检测方法

王文善^{1,2}, 郭永存^{1,2,3,4}, 刘普壮^{1,2}, 杨 豚^{1,2}, 童佳乐^{1,2}

(1. 安徽理工大学 深部煤矿采动响应与灾害防控国家重点实验室, 安徽 淮南 232001; 2. 安徽理工大学 机械工程学院, 安徽 淮南 232001; 3. 矿山智能技术与装备省部共建协同创新中心, 安徽 淮南 232001; 4. 安徽理工大学 矿山智能装备与技术安徽省重点实验室, 安徽 淮南 232001)

摘 要:针对输送带纵向撕裂检测中存在的检测视角单一、速度慢、精度低等问题,文章提出一种基于改进 YOLOv3 算法的输送带纵向撕裂多视角检测方法。首先对原始 YOLOv3 网络结构进行优化设计,采用 29 层网络模型(Darknet-29)作为特征提取网络,将原有的 3 种不同尺度锚点改为 2 种不同尺度(26×26 , 52×52)锚点;将位于多视角检测点的工业相机所采集的纵向撕裂图像制作成数据集,使用 K -means 算法对输送带纵向撕裂标签进行维度聚类分析,确定先验框参数;最后将改进的 YOLOv3 算法在数据集上进行测试与训练,并与其他几种算法进行比较。实验结果表明:该检测方法不仅可以较好地检测出输送带纵向撕裂,还可以分类识别出大裂纹或完全撕裂情形;相较于原始 YOLOv3 算法,改进后的 YOLOv3 算法平均检测精度均值提高 0.4%,达到 98.7%,检测速度提高 60.6%,达到 53 帧/s,模型占用内存减少 93 Mb,仅为 141 Mb,优于 YOLOv2 和 YOLOv3-Tiny 算法。该文提出的输送带纵向撕裂检测方法具有模型占用内存低、检测精度高及速度快等优点,为输送带纵向撕裂提供了一种新的检测方案。

关键词:YOLOv3 算法;纵向撕裂;多视角;Darknet-29 网络模型; K -means 聚类

中图分类号:TD 679 **文献标志码:**A **文章编号:**1003-5060(2023)01-0028-09

Multi-view detection method for longitudinal tear of conveyor belt based on improved YOLOv3

WANG Wenshan^{1,2}, GUO Yongcun^{1,2,3,4}, LIU Puzhuang^{1,2}, YANG Tun^{1,2}, TONG Jiale^{1,2}

(1. State Key Laboratory of Mining Response and Disaster Prevention and Control in Deep Coal Mines, Anhui University of Science and Technology, Huainan 232001, China; 2. School of Mechanical Engineering, Anhui University of Science and Technology, Huainan 232001, China; 3. Collaborative Innovation Center for Mining Intelligent Technology and Equipment, Huainan 232001, China; 4. Anhui Key Laboratory of Mine Intelligent Equipment and Technology, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to solve the problems of single view, slow speed and low accuracy in longitudinal tear detection of conveyor belt, multi-view detection for longitudinal tear of conveyor belt based on improved YOLOv3 algorithm is proposed. Firstly, the original YOLOv3 network structure was optimized and the Darknet-29 network model was used as the feature extraction network. The original three anchor points with different scales were replaced with two anchor points with different scales (26×26 , 52×52). Secondly, the longitudinal tear image collected by the industrial camera located at the multi-view detection point was made into a data set. K -means algorithm was used to conduct dimensional clustering analysis on the longitudinal tear label of conveyor belt, and the prior box parameters were determined. Finally, the improved YOLOv3 algorithm was tested and trained on the data set, and compared with other algorithms. The experimental results show that this method can not on-

收稿日期:2021-08-23;修回日期:2021-12-01

基金项目:国家重点研发计划资助项目(2020YFB1314203);国家自然科学基金资助项目(51874004;51904007)和安徽省自然科学基金资助项目(1908085QE227)

作者简介:王文善(1992—),男,安徽怀远人,安徽理工大学博士生;
郭永存(1965—),男,安徽舒城人,博士,安徽理工大学教授,博士生导师。

ly detect the longitudinal tear well, but also identify the large crack or complete tear. Compared with the original YOLOv3 algorithm, the improved YOLOv3 algorithm improves the mean average precision(mAP) by 0.4% to 98.7%, improves the detection speed by 60.6% to 53 FPS, and reduces the memory footprint of the model by 93 Mb to 141 Mb, which is better than YOLOv2 and Yolov3-Tiny algorithms. Therefore, the proposed detection method for longitudinal tear of conveyor belt has the advantages of low model memory occupation, high detection accuracy and fast speed, which can provide a new detection scheme for longitudinal tear of conveyor belt.

Key words: YOLOv3 algorithm; longitudinal tear; multi-view; Darknet-29 network model; K-means clustering

0 引 言

带式输送机是以输送带兼作牵引机构和承载机构的一种连续动作式运输设备,因具有长运距、大运量、连续运输、运行可靠等优点,已成为煤炭高效开采的关键设备^[1-3]。在带式输送机中,输送带是承接物料最关键的部分。然而纵向撕裂是输送带损伤最为严重的形式,主要表现为出现较大裂纹或完全撕裂。输送带纵向撕裂主要发生在带式输送机的装载点处,其主要原因是落料口落下的物料时常会夹带着具有锐利边口的异物(如大块矸石和金属材料等),极易扎伤输送带,若没有及时发现,不但会撕裂整条输送带,还将使整个运输系统停车而影响生产,造成巨大的经济损失^[4-8]。因此,对输送带纵向撕裂的实时检测具有重要意义。

传统的输送带纵向撕裂检测方法有预填线圈检测法^[9]、接触检测法^[10]、漏料检测法^[11]等,由于煤矿恶劣环境的影响,这些检测设备因稳定性和准确性低而逐渐被淘汰。目前有多位学者将机器视觉技术应用于带式输送机的纵向撕裂检测中。文献^[12]提出了基于激光的输送带纵向撕裂在线机器视觉检测方法,利用可见光 CMOS 摄像机采集输送带图像,然后分析判断输送带表面是否有裂口;文献^[13]提出了一种基于红外和可见光融合的输送带纵向撕裂双目视觉检测方法,该方法相较于文献^[12]方法在一定程度上提高了纵向撕裂的检测精度;文献^[14]提出了输送带纵向撕裂检测预警的红外光谱分析方法,与现有的大多数方法不同,该方法通过红外热成像技术监测纵向撕裂的红外辐射场的变化过程,并通过红外辐射场的频域特征示数 T 来判断输送带是否存在纵向撕裂的隐患,进一步提高输送带纵向撕裂识别准确度;文献^[15]提出了输送带纵向撕裂的多光谱视觉检测方法,该方法也可分类识别输送

带的其他状态;文献^[16]提出基于 Haar-Ada-Boost 和级联算法的不均匀光照下输送带纵向撕裂检测方法;文献^[17]采用弱磁检测技术、红外热成像技术和视觉检测技术等研发了一套矿用带式输送机智能监测系统,通过将多种检测技术融合,提高了纵向撕裂检测性能。文献^[12-16]为输送带纵向撕裂检测提供了新方法,但是这些方法都是基于手工特征的传统算法,需要对采集的数据进行繁琐的预处理,且主要检测点位于输送带下表面,易忽略未贯穿的大裂纹形式,存在检测视角单一、速度慢和精度低等问题。

近些年,深度学习技术的快速发展为输送带纵向撕裂提供了快速检测的新方法。基于深度学习的检测算法大致可分为 2 类:一类是 two stage 方法,主要以 R-CNN 算法^[18-20]为主;另一类是 one stage 方法,主要以 SSD 算法^[21-23]和 YOLO 算法^[24-26]为主。two stage 方法在检测准确率和定位精度上占优,one stage 方法在算法速度上占优。YOLO 是第 1 个在检测精度、检测速度上都取得优异效果的单阶段目标检测算法,其第 3 代 YOLOv3 算法相较于之前的算法,尤其是针对小目标,检测精度有显著提升,在实时目标检测领域中具有较高的研究和应用价值。然而传统 YOLOv3 算法借鉴残差神经网络(Resnet)模型搭建出 53 层神经网络(Darknet-53),较多的网络层数虽然对特征提取是有利的,但相应也会产生梯度消失现象以及降低检测速度,且本文中只需检测输送带纵向撕裂这一类目标,并不需要很复杂的网络层数。

鉴于此,本文提出一种基于改进 YOLOv3 算法的输送带多视角检测方法。首先,该方法对原始 YOLOv3 算法网络进行改进设计,将 Darknet-53 简化为 Darknet-29,将原有的 3 种不同尺度锚点改用为 2 种不同尺度锚点进行检测;其次,搭建实验平台制作纵向撕裂数据集,选用 K-means 算

法对纵向撕裂标签进行聚类分析,确定先验框参数。实验结果表明:该方法不仅能较好地检测出输送带纵向撕裂,还可以分类识别出大裂纹或完全撕裂情形;改进后的 YOLOv3 算法对于输送带纵向撕裂的检测效果比改进前有明显提高。

1 纵向撕裂多视角检测方法

本文提出一种基于改进 YOLOv3 算法的输

送带纵向撕裂多视角检测方法,该方法通过架设在垂直于输送带上、下两面的工业相机实时采集输送带运行图像。

多视角检测实验平台如图 1 所示。

图 1 中:上表面检测相机悬挂在落料口前侧无煤处正上方;下表面检测相机安装在上、下输送带之间;光源为可调节白光,照射角度均为正面照射。




图 1 纵向撕裂检测实验装置

将采集的图像数据送入改进的 YOLOv3 网络中进行检测, YOLOv3 算法检测分为 2 步:第 1 步识别纵向撕裂在输送带上的位置,在图像上对识别出的纵向撕裂区域自动裁剪获得纵向撕裂图像;第 2 步针对纵向撕裂图像进行分类识别。最后,针对识别出的大裂纹图像和完全撕裂图像给出不同图像处理信号。

实验平台中使用的输送带是一种常见的煤矿用钢丝绳输送带,该输送带带宽为 0.6 m,厚度为 15 mm;输送机总长度为 4 m,最大运行速度为 4 m/s。

本实验装置所用相机型号为海康威视 MV-CA050-11UM/UC、机器视觉检测 500 万像素 USB3.0 工业相机;相机镜头型号为 WL1406-5MP (6 mm 焦距);光源型号为 KM-BRD36030-白光 (2 个);光源控制器型号为 DSC2.0-2C030W-24PS(60 W),可调节光源亮度;镜头滤镜使用工业滤光片。

本实验所有的训练和测试均在同一计算机硬件平台上进行,训练和测试模型使用图形处理器 GPU,所有程序在 Ubuntu 18.04 系统上运行,具体配置见表 1 所列。

表 1 实验环境

要素	内容
CPU	Intel(R) Core(TM) i7 CPU @ 2.90 GHz
GPU	NVIDIA GeForce RTX2060
系统	Ubuntu 18.04
语言	Python3.6
加速环境	CUDA10.0, Cudnn7.3

2 YOLOv3 算法及改进设计

2.1 检测原理

YOLOv3 算法中引入了多尺度特征金字塔网络(feature Pyramid network, FPN),通过上采样操作使深层特征的尺度变为与浅层特征尺度相同的特征,进而将深层特征和浅层特征进行融合。在图像特征提取方面, YOLOv3 采用 Darknet-53 的网络结构(含有 53 个卷积层),相较于 YOLOv2 中的特征提取网络 Darknet-19 引入了残差网络结构,加深了网络的深度^[27]。

YOLOv3 检测时,首先将输入的图片分割成 $S \times S$ 个网格,然后进行边界框的预测。预测框示

意图如图 2 所示。




图 2 预测框示意图

YOLOv3 沿用 YOLO9000 预测边界框的方法,通过尺寸聚类确定先验框(Anchor box)大小,如图 2 中红色虚线所示。图 2 中: t_x 、 t_y 、 t_w 、 t_h 表示网格的预测值,在每个网格中输出对应于网格的相对中心坐标 $(\sigma(t_x), \sigma(t_y))$; p_w 、 p_h 分别表示先验框的宽和高; c_x 和 c_y 表示网格相对于左上角的偏移量。边界框的值可以表示为:

$$\begin{aligned} b_x &= \sigma(t_x) + c_x, & b_y &= \sigma(t_y) + c_y, \\ b_w &= p_w e^{t_w}, & b_h &= p_h e^{t_h}, & \sigma(x) &= 1/(1 + e^{-x}) \end{aligned} \quad (1)$$

预测框的中心点位置、宽、高、置信度以及分类信息是损失函数计算的重要参数值。预测框的置信度可用预测框与标记框之间的交并比(intersection over union, IoU)表示,其计算公式为:

$$P_{IoU} = \frac{B_1 \cap B_2}{B_1 \cup B_2} \quad (2)$$

其中: B_1 为预测框; B_2 为标记框。一般设置如下: $P_{IoU} > 0.7$ 的预测框为正例,即成功预测目标; $P_{IoU} < 0.3$ 的目标为反例,即背景。计算损失函数时,需尽量保持正、反例之间数量平衡。

2.2 损失函数

损失函数是用来评估模型真实值与预测值不一致程度的非负实值函数,损失值越小,模型的预测能力、鲁棒性越好。因此,本文 YOLOv3 算法在训练神经网络时优化的是损失函数,通过反向传播对模型不断进行更新,使得 Loss 逐渐减小,最终趋于稳定状态。

YOLOv3 的损失函数采用误差的平方并整合了预测框定位误差、有无目标的 IOU 误差以及分类误差。损失函数的计算公式如下:

$$\begin{aligned} L_{\text{loss}} &= \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\ &\sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] + \\ &\sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 + \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B l_{ij}^{\text{obj}} (C_i - \hat{C}_i) + \\ &\sum_{i=0}^{S^2} l_i^{\text{noobj}} \sum_{C \in \text{classes}} [p_i(c) - \hat{p}_i(c)]^2 \end{aligned} \quad (3)$$

其中: S 为图像的划分系数; B 为每一个边界框; x_i 、 y_i 分别为预测目标的 x 轴和 y 轴坐标; \hat{x}_i 、 \hat{y}_i 分别为实际目标的 x 轴和 y 轴坐标; w_i 、 h_i 分别为预测目标的宽和高; \hat{w}_i 、 \hat{h}_i 分别为实际目标的宽和高; $p_i(c)$ 为预测目标置信度; $\hat{p}_i(c)$ 为实际目标置信度; λ_{coord} 、 λ_{noobj} 分别为权重系数和惩罚权重系数;obj、noobj 分别表示含有目标和不含目标。

2.3 网络结构改进设计

原始 YOLOv3 算法借鉴残差神经网络模型搭建出 53 层神经网络 Darknet-53,该网络结构包含 52 个卷积层和 1 个全连接层。较多的网络层数虽然对特征提取是有利的,但相应也会产生梯度消失现象以及增加检测时间,而且纵向撕裂只有大裂纹和完全撕裂 2 种类别,并不需要深层神经网络提取特征,因此本文运用类似于 Darknet-53 的网络模型搭建出 29 层网络模型 Darknet-29,如图 3 所示。

	类型	通道数	尺寸	输出
	Convolutional	32	3×3	416×416
	Convolutional	64	3×3	208×208
1×	Convolutional	32	1×1	
	Convolutional	64	3×3	208×208
	Residual			208×208
2×	Convolutional	128	3×3/2	104×104
	Convolutional	64	1×1	
	Convolutional	128	3×3	
	Residual			104×104
2×	Convolutional	256	3×3/2	52×52
	Convolutional	128	1×1	
	Convolutional	256	3×3	
	Residual			52×52
2×	Convolutional	512	3×3/2	26×26
	Convolutional	256	1×1	
	Convolutional	512	3×3	
	Residual			26×26
4×	Convolutional	1 024	3×3/2	13×13
	Convolutional	512	1×1	
	Convolutional	1 024	3×3	
	Residual			13×13

图 3 Darknet-29 网络结构

改进后的 YOLOv3 网络结构如图 4 所示,其网络的基本组件 Darknet-Conv 是卷积层(convolutional, Conv)、批归一化(batch normalization,

BN)以及激活函数层 Leaky ReLU 的集成。在所有的卷积层后增加批归一化,有助于加快训练过程并提高性能,同时可以缓解梯度消失问题。Leaky ReLU 是 ReLU 激活函数的变体,在负值输入时有很小的坡度,解决了 ReLU 函数进入负区间后神经元不学习的问题。YOLOv3 的大组件 Res n 是由 Darknet-Conv、Zero padding 和 n 个残差单元 Residual 构成,这一结构有助于解决网络层数增

加后梯度爆炸和梯度消失的问题。整个网络结构可以分为 Darknet-29 部分和 YOLO 部分,Darknet-29 由卷积层和残差网络组成,每个卷积层包括 1×1 的卷积块 CB1 和 3×3 的卷积块 CB2,用于提取图像特征;YOLO 部分通过借鉴 FPN 特征网络的思想进行多尺度特征融合,通过添加上采样层和连接层,融合了 2 个不同尺度的特征,在 2 个尺度的融合特征图上分别独立做检测。

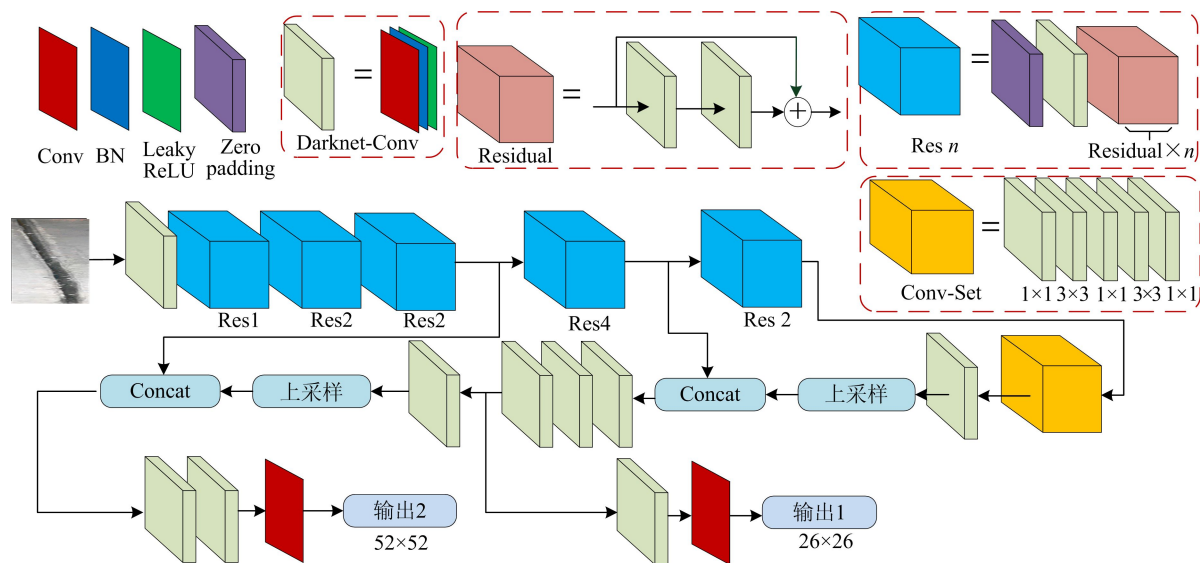


图 4 改进的 YOLOv3 网络结构

3 实验与结果分析

3.1 数据集制作与处理

数据在深度学习中占有重要地位,数据集的优劣对实际生产环境中输送带纵向撕裂的检测有着重要影响。本文采用图 1 所示的实验装置制作数据集,共采集大裂纹和完全撕裂的图片各 300 张。在深度学习中,样本数量越丰富,训练出来的模型效果越好,因此,需对原始数据进行数据增强处理,其中色调的变化范围为 $1.0 \sim 1.5$ 倍,曝光的变化范围为 $1.0 \sim 1.5$ 倍,色量的变化范围为 $0.9 \sim 1.1$ 倍。通过数据增强技术,最终得到 1 780 张图片,其中大裂纹 850 张,完全撕裂 930 张,将所有图片按照 7 : 3 分为训练集和测试集。

使用 labelImg 工具对数据集进行人工边框标记,标注信息以 PASCAL VOC 格式存储,其中包含大裂纹和完全撕裂的类别和边框坐标。然后将数据进行预处理归一化操作,将目标实际标记框数据除以图像的高度和宽度,使得预处理数据被限制在 $0 \sim 1$ 之间,可使训练过程更快读取数

据,加速模型收敛。归一化操作后 5 个参数组成 1 组数据,分别包含分类序列(label)、标记框中心的 x 坐标和 y 坐标、标记框的宽 w 、标记框的高 h ,其表达式^[28]如下:

$$\begin{aligned} x &= \frac{x_{\max} + x_{\min}}{2w_p}, & y &= \frac{y_{\max} + y_{\min}}{2h_p}, \\ \omega &= \frac{x_{\max} - x_{\min}}{w_p}, & h &= \frac{y_{\max} - y_{\min}}{h_p} \end{aligned} \quad (4)$$

其中: (x_{\max}, y_{\max}) 为标记框右下角坐标; (x_{\min}, y_{\min}) 为标记框左上角坐标; w_p, h_p 分别为图像的高和宽。

3.2 数据集标签聚类分析

Anchor 参数是一组固定宽度与高度的先验框(从训练集中标记的真实边界框中聚类得到的不同尺寸的框),通过维度聚类找到具有代表性的框,避免训练模型时盲目寻找合适的框,有助于加速模型收敛。使用 K-means 聚类算法对输送带纵向撕裂标签进行维度聚类分析,获得针对输送带纵向撕裂具有代表性的 anchor 参数。通过变换 K 的取值,聚类分析得到不同 K 值对应的先验框大小。引入平均交并比(\bar{P}_{IoU})即多组输送带

纵向撕裂样本标记边界框与先验框的平均交并比, \bar{P}_{IoU} 越大, 聚类分析效果越好。

不同 K 值对应的平均交并比如图 5 所示。从图 5 可以看出: 随着 K 值增大, \bar{P}_{IoU} 值逐渐增大, 聚类分析效果逐渐提高; 但当 K 值超过 6 后出现先验框大小较为相近的聚类结果, 产生冗余。因此取 $K = 6$, 即先验框大小为 (16, 556)、(21, 537)、(27, 560)、(33, 571)、(43, 561)、(56, 583) 时的聚类分析结果作为输送带纵向撕裂检测的 anchor 先验框参数进行训练和测试, 相较于原始参数, 本文聚类分析结果较为集中, 使得算法在训练过程中更容易收敛。




图 5 不同 K 值对应的平均交并比

3.3 模型的训练与评估

网络模型训练前需设置相应训练参数, 合适的参数值可以训练出较优的模型, 本文设置的参数见表 2 所列, 每次迭代过程加载 64 张图片并分 16 批次完成向前传播过程, 待 64 张图片全部完成向前传播后, 再进行一次反向传播更新参数。引入最优化方法中动量 (momentum) 参数, 影响梯度下降到最优值的速度; 引入权重衰减正则项 (decay), 防止模型训练过程中出现过拟合现象。模型一共训练 5 000 次, 共耗时 6 h。

表 2 网络训练参数

参数	数值
batch	64
subdivisions	16
iterations	5 000
learning rate	0.001
momentum	0.9
decay	0.000 5
steps	4 000, 4 500
scales	0.1, 0.1

本实验使用精确度 (precision)、召回率 (recall)、平均精度 (average precision, AP)、所有目标类别平均检测精度的均值 (mean average precision, mAP) 以及每秒检测的图片数量 (frame per second, FPS) 来评价损失函数训练出来的模型性能^[29]。

精确度 P_{re} 、召回率 R_c 、mAP、FPS 的计算公式分别如下:

$$P_{re} = \frac{T_P}{T_P + F_P} \quad (5)$$

$$R_c = \frac{T_P}{T_P + F_N} \quad (6)$$

$$P_{mAP} = \frac{\sum_{i=0}^n P_A(i)}{n} \quad (7)$$

$$f_{FPS} = \frac{N_{figure}}{t_{total}} \quad (8)$$

其中: T_P 为真实的正样本数量; F_P 为虚假的正样本数量; F_N 为虚假的负样本数量; n 为类别数; $P_A(i)$ 为某一类的检测精度; N_{figure} 为检测图片总数; t_{total} 为检测总时间。

3.4 实验结果分析

输送带纵向撕裂检测结果如图 6 所示。其中: 图 6a 为完全撕裂 (L-T) 检测结果, 图 6b 为大裂纹 (L-C) 检测结果。

相对于传统单维度检测方法, 本文基于改进 YOLOv3 算法的输送带纵向撕裂多视角检测方法不仅可以有效解决输送带纵向撕裂问题, 而且可以进行多目标分类识别, 自动识别出大裂纹或者完全撕裂情形。




图 6 纵向撕裂检测结果

改进模型的精度对比如图 7 所示。从图 7 可以看出, 使用改进后的 YOLOv3 算法进行检测时, 输送带纵向撕裂所有类别的平均检测精度

AP 相较于原始 YOLOv3 算法均没有下降,在保证检测精度的同时,显著增加了检测速度。




图 7 改进模型的精度对比

模型分解实验结果见表 3 所列。其中:模型 A 为原始 YOLOv3 模型;模型 B 为在模型 A 的基础上简化特征提取网络,搭建出 29 层特征提取网络 Darknet-29 后的模型;模型 C 为在模型 A 的基础上减少 1 个特征尺度后的模型;模型 D 为在模型 A 的基础上引入 Darknet-29 和减少 1 个特征尺度后的模型。

从表 3 可以看出,简化特征提取网络和减少 1 个特征尺度,对输送带纵向撕裂的检测精度影响不大,但是会显著提高检测速度。这是由于纵向撕裂的类别较少且各种类别尺寸相对集中,特征提取相对简单,不需要较多的网络层。

表 3 模型分解实验结果

模型	YOLOv3 及其改进	各类目标的平均检测精度/%		$P_{mAP}/\%$	$f_{FPS}/(\text{帧} \cdot \text{s}^{-1})$
		大裂纹	完全撕裂		
A	Darknet53 YOLOv3	96.8	99.7	98.3	33
B	模型 A+Darknet-29	94.7	99.9	97.3	45
C	模型 A+减少 1 个特征尺度	97.9	98.6	98.2	36
D	模型 A+Darknet-29+减少 1 个特征尺度	97.5	99.9	98.7	53

通过与几种先进的 YOLO 检测算法比较发现,改进后的 YOLOv3 算法对于输送带纵向撕裂检测效果最好。

不同算法损失值迭代曲线的对比如图 8 所示。

从图 8 可以看出,在相同的网络训练参数和硬件配置下,改进后的 YOLOv3 算法(YOLOv3-darknet29)损失值最低,模型效果最优;模型在前 2 300 次训练中迅速拟合,Loss 值快速变小,在 3 000 次训练后逐渐趋于稳定,达到理想效果。

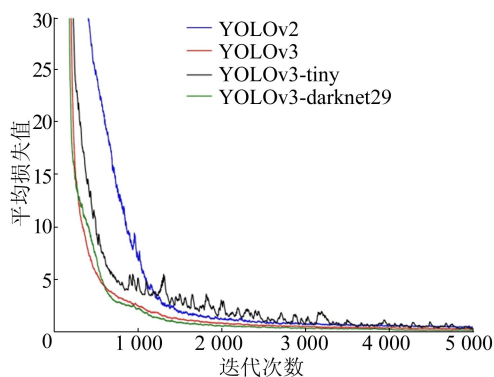


图 8 不同算法损失值迭代曲线的对比

不同 YOLO 算法的检测性能对比见表 4 所列。

从表 4 可以看出:改进后的 YOLOv3 算法所

有目标类别检测精度的均值 P_{mAP} 为 98.7%,在几种算法中最高,相较于原始 YOLOv3 算法、YOLOv2 算法和 YOLOv3-Tiny 算法,分别提高 0.4%、8.1%、10.8%;YOLOv3-Tiny 算法由于网络结构简单,其检测速度为 132 帧/s,在几种算法中最快,但是其 P_{mAP} 只有 87.9%,难以满足实际生产环境中的精度要求,故不可取;改进后的 YOLOv3 算法在保证检测精度的条件下,具有较高的检测速度,相较于原始 YOLOv3 算法提高 60.6%,相较于 YOLOv2 算法提高 39.5%。

表 4 不同 YOLO 算法的检测性能对比

算法	$f_{FPS}/(\text{帧} \cdot \text{s}^{-1})$	$P_{mAP}/\%$	$P_A/\%$	
			大裂纹	完全撕裂
YOLOv2	38	90.6	86.7	94.5
YOLOv3-Tiny	132	87.9	86.8	89.1
YOLOv3	33	98.3	96.8	99.7
改进 YOLOv3	53	98.7	97.5	99.9

网络模型在保证精度和速度的前提下所占用的内存越少,与硬件结合越有利。

不同 YOLO 系列算法网络模型所占用内存大小如图 9 所示。

从图 9 可以看出:YOLOv3-Tiny 算法占用内存最少,仅为 33 Mb,这是由于 YOLOv3-Tiny 网

络结构比较简单;其次是改进后的 YOLOv3 算法,其占用内存大小为 141 Mb,相较于原始 YOLOv3 算法和 YOLOv2 算法分别减少 93 Mb 和 51 Mb。

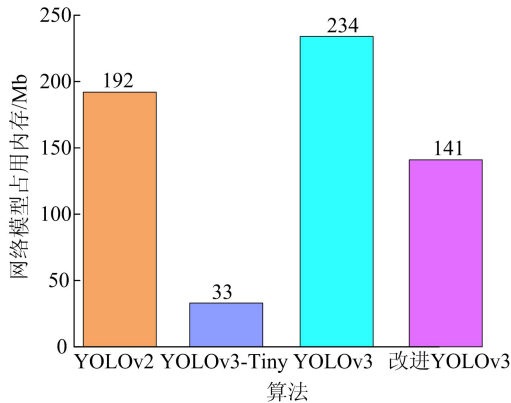


图 9 不同 YOLO 系列算法网络模型占用内存

从各种算法的检测速度 f_{FPS} 、整体检测精度 P_{mAP} 和模型占用内存可以看出,改进后的 YOLOv3 算法在输送带纵向撕裂检测方面优于其他几种算法,既具有较高的检测精度,又能保证较快的检测速度,可以满足输送带运行过程中实时检测的精度与速度要求。

4 结 论

针对输送带纵向撕裂检测中存在的检测视角单一、速度慢、精度低等问题,本文提出一种基于改进 YOLOv3 算法的输送带纵向撕裂多视角检测方法。该方法对输送带检测装置进行改进设计,利用多个视角布置的工业相机采集输送带图像;对原始 YOLOv3 网络进行优化调整,从而获得一种快速、准确的端到端输送带纵向撕裂检测方法。根据实验结果得到以下结论:

(1) 输送带纵向撕裂多视角检测方法不仅可有效解决输送带纵向撕裂问题,还可以进行多目标分类识别,自动识别出大裂纹或完全撕裂情形。

(2) 相较于原始 YOLOv3 算法,改进后的 YOLOv3 算法平均检测精度均值 P_{mAP} 在没有下降的情况下,检测速度提高了 60.6%,达到 53 帧/s,模型占用内存减少了 93 Mb,仅为 141 Mb。

(3) 与其他算法性能的对比结果表明,改进后的 YOLOv3 算法在输送带纵向撕裂检测方面优于 YOLOv2、YOLOv3-Tiny 和原始 YOLOv3 算法,能够较准确快速地检测出输送带纵向撕裂问题。

【参 考 文 献】

[1] 杨小林,葛世荣,祖洪斌,等. 带式输送机永磁智能驱动系统

及其控制策略[J]. 煤炭学报,2020,45(6):2116-2126.

[2] 王国法,任怀伟,庞义辉,等. 煤矿智能化(初级阶段)技术体系研究与工程进展[J]. 煤炭科学技术,2020,48(7):1-27.

[3] 郭永存,何家锐,李成林. 基于永磁涡流传动的长距离带式输送机启动特性研究[J]. 煤炭科学技术,2020,48(1):54-60.

[4] 曹虎奇. 煤矿带式输送机撕带断带研究分析[J]. 煤炭科学技术,2015,43(增刊2):130-134.

[5] 刘伟力,乔铁柱. 矿用输送带纵向撕裂检测系统研究[J]. 工矿自动化,2017,43(2):78-81.

[6] 吴守鹏. 基于机器视觉的运煤皮带异物识别方法研究[D]. 徐州:中国矿业大学,2019.

[7] PETRIKOVA I, MARVALOVA B, SAMAL S, et al. Digital image correlation as a measurement tool for large deformations of a conveyor belt [J]. Applied Mechanics and Materials, 2015, 732: 77-80.

[8] 杨祥. 矿用胶带输送机监测监控及故障诊断系统的开发[D]. 太原:太原理工大学,2019.

[9] PANG Y, LODEWIJKS G. A novel embedded conductive detection system for intelligent conveyor belt monitoring [C]//2006 IEEE International Conference on Service Operations and Logistics, and Informatics. [S. l.]: IEEE, 2007: 803-808.

[10] MOLNÁR V, FEDORKO G, ANDREJIOVÁ M, et al. Analysis of influence of conveyor belt overhang and cranking on pipe conveyor operational characteristics[J]. Measurement, 2015, 63: 168-175.

[11] RYSZARD B, LESZEK J, TOMASZ K, et al. The use of magnetic sensors in monitoring the condition of the core in steel cord conveyor belts: tests of the measuring probe and the design of the DiagBelt system[J]. Measurement, 2018, 123: 48-53.

[12] LI X G, SHEN L F, MING Z X, et al. Laser-based on-line machine vision detection for longitudinal rip of conveyor belt[J]. Optik, 2018, 168: 360-369.

[13] QIAO T Z, CHEN L L, PANG Y S, et al. Integrative binocular vision detection method based on infrared and visible light fusion for conveyor belts longitudinal tear [J]. Measurement, 2017, 110: 192-201.

[14] YANG R Y, QIAO T Z, PANG Y S, et al. Infrared spectrum analysis method for detection and early warning of longitudinal tear of mine conveyor belt[J]. Measurement, 2020, 165: 107856.

[15] HOU C C, QIAO T Z, ZHANG H T, et al. Multispectral visual detection method for conveyor belt longitudinal tear [J]. Measurement, 2019, 143: 246-257.

[16] WANG G X, ZHANG L B, SUN H, et al. Longitudinal tear detection of conveyor belt under uneven light based on Haar-AdaBoost and Cascade algorithm [J]. Measurement, 2021, 168: 108341.

[17] 毛清华,毛金根,马宏伟,等. 矿用带式输送机智能监测系统研究[J]. 工矿自动化,2020,46(6):48-52,58.

(下转第 80 页)

[参 考 文 献]

- [1] 吴拓. 斜拉桥 π 型主梁截面涡激振动性能的人工智能识别[D]. 西安:长安大学, 2018.
- [2] KUBO Y, SADASHIMA K, YAMAGUCHI E, et al. Improvement of aeroelastic instability of shallow π section[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2001, 89:1445-1457.
- [3] 李欢, 何旭辉, 王汉封, 等. π 型截面超高斜拉桥涡振减振措施风洞试验研究[J]. 振动与冲击, 2018, 37(7):70-76.
- [4] WANG Z X, ZHANG Z T. VIV properties of π -shaped bridge sectional model; dependence on torsional-bending frequency ratio [J]. Journal of Bridge Engineering, 2021, 26(6):06021003-1-06021003-5.
- [5] GE Y J, XIANG H F. Recent development of bridge aerodynamics in China[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2008, 96:736-768.
- [6] GE Y J, XIANG H F, TANAKA H. Application of a reliability analysis model to bridge flutter under extreme winds [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2000, 86:155-167.
- [7] LI L Y, WU T, HE X H, et al. Reliability evaluation of vortex-induced vibration for a long-span arch bridge[J]. Journal of Bridge Engineering, 2018, 23(5):05018002-1-05018002-5.
- [8] 张明, 金峰. 结构可靠性计算[M]. 北京:科学出版社, 2015:204-245.
- [9] KADAPA C. A second-order accurate non-intrusive staggered scheme for the interaction of ultra-lightweight rigid bodies with fluid flow [J]. Ocean Engineering, 2020, 217:107940.
- [10] 刘十一. 大跨度桥梁非线性气动力模型和非平稳全过程风致响应[D]. 上海:同济大学, 2014.
- [11] 祝卫亮, 刘十一, 周志勇, 等. 流固耦合数值模拟中的 HOPE 网格变形方法[C]//中国土木工程学会桥梁及结构工程分会风工程委员会, 中国空气动力学学会风工程和工业空气动力学专业委员会. 第十八届全国结构风工程学术会议暨第四届全国风工程研究生论坛论文集. 长沙:中南大学出版社有限责任公司, 2017:643-644.
- [12] 赵林, 刘丛菊, 葛耀君. 桥梁结构涡激共振的敏感性[J]. 空气动力学学报, 2020, 38(4):694-704.
- [13] 李湛, 李鹏飞, 姜震宇, 等. 不同激励模式下桥梁实测阻尼比差异[J]. 振动与冲击, 2016, 35(4):62-67.
- [14] 王卓, 闫维明, 秦栋涛, 等. 钢混筒支梁加载损伤后耗能特征试验研究[J]. 振动、测试与诊断, 2009, 29(1):71-75, 123-124.
- [15] 同济大学. 公路桥梁抗风设计规范:JTJ/T 3360-01—2018[S]. 北京:人民交通出版社股份有限公司, 2019:79-80.
- [16] 罗东伟. 开槽箱梁涡激振动及其控制措施研究[D]. 上海:同济大学, 2013.

(责任编辑 张淑艳)

(上接第 35 页)

- [18] LI C Y, SONG D, TONG R F, et al. Illumination-aware Faster R-CNN for Robust Multispectral Pedestrian Detection [J]. Pattern Recognition, 2018, 85:161-171.
- [19] WAN H H, SOTIRIOS G. Faster R-CNN for multi-class fruit detection using a robotic vision system [J]. Computer Networks, 2020, 168:107036.
- [20] 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 & Machine Intelligence, 2017, 39:1137-1149.
- [21] HUANG X P, HU Z L, WANG X R, et al. An improved single shot multibox detector method applied in body condition score for dairy cow[J]. Animals: An Open Access Journal From MDPI, 2019, 9(7):31340515.
- [22] PAN H D, JIANG J, CHEN G F. TDFSSD: top-down feature fusion single shot multibox detector[J]. Signal Processing Image Communication, 2020, 89(4):115987.
- [23] JEONG J, PARK H, KWAK N. Enhancement of SSD by concatenating feature maps for object detection [C]//British Machine Vision Conference. [S. l.]: arXiv, 2017. <https://doi.org/10.48550/arXiv.1705.09587>.
- [24] TIAN Y N, YANG G D, WANG Z, et al. Apple detection during different growth stages in orchards using the improved YOLO-V3 model [J]. Computers and Electronics in Agriculture, 2019, 157:417-426.
- [25] HENDRY, CHEN R C. Automatic License Plate Recognition via sliding-window darknet-YOLO deep learning [J]. Image and Vision Computing, 2019, 87:47-56.
- [26] 张姝, 王昊天, 董骁翀, 等. 基于深度学习的输电线路螺栓检测技术[J]. 电网技术, 2021, 45(7):2821-2829.
- [27] 吕石磊, 卢思华, 李震, 等. 基于改进 YOLOv3-LITE 轻量级神经网络的柑橘识别方法[J]. 农业工程学报, 2019, 35(17):205-214.
- [28] 赵德安, 吴任迪, 刘晓洋, 等. 基于 YOLO 深度卷积神经网络的复杂背景下机器人采摘苹果定位[J]. 农业工程学报, 2019, 35(3):164-173.
- [29] 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.

(责任编辑 胡亚敏)