

DOI: 10.13382/j.jemi.B2206008

基于改进 YOLOX 的电铲铲齿断裂检测方法*

卢进南 刘 扬 王连捷 黎 洛
(辽宁工程技术大学机械工程学院 阜新 123000)

摘 要:电铲是露天采矿中广泛使用的一种大型机械挖掘设备。在挖掘过程中,铲齿与矿石长时间的直接冲击会造成铲齿过早的松动甚至断裂,从而导致电铲计划外的停机和生产力的损失。针对这个问题,提出了一种基于改进 YOLOX 的电铲铲齿断裂检测方法。该方法以 YOLOX 为基础,首先针对受光照不均匀等影响导致检测效果差的问题,在特征金字塔网络加入扩张卷积注意力机制增强目标在复杂背景中的显著度;其次使用 CEIOU (corner efficient intersection over union) 损失函数代替原网络损失函数优化网络的训练过程,进而提高目标的检测精度;最后考虑嵌入式设备本身的计算能力问题,利用模型压缩策略裁剪网络中冗余通道,减少模型体积并提高检测速度。在自主构建的 4 200 张 WK-10 型电铲数据集上进行性能测试,实验结果表明:与 YOLOX 网络模型相比,改进后模型的平均检测精度达到了 95.37%,提高了 1.95%,检测速度为 46.1 fps,提升了 8.4 fps,模型体积为 31.74 MB,减少到原来的 32.9%。对比多种其他现存方法,所设计的目标检测算法有着精度高、体积小和速度快的优势。

关键词: 铲齿;目标检测;YOLOX;扩张卷积注意力;CEIOU;模型压缩

中图分类号: TP751.1 **文献标识码:** A **国家标准学科分类代码:** 520.20

Electric shovel tooth break detection method based on improved YOLOX

Lu Jinnan Liu Yang Wang Lianjie Li Luo

(School of Mechanical Engineering, Liaoning University of Engineering and Technology, Fuxin 123000, China)

Abstract: Electric shovel is a large mechanical excavation equipment widely used in surface mining. During the excavation process, the prolonged direct impact of the shovel teeth against the ore can cause the shovel teeth to loosen or even break prematurely, resulting in unplanned downtime and lost productivity of the shovel. To solve this problem, an electric shovel tooth break detection method based on the improved YOLOX is proposed. This method is based on YOLOX. Firstly, for the problem of poor detection effect caused by uneven illumination, the dilated convolution attention mechanism is added to the feature pyramid network to enhance the saliency of the target in the complex background; Secondly, the corner efficient intersection over union (CEIOU) loss function is used to replace the original network loss function to optimize the network training process, thereby improving the detection accuracy of the target; Finally, considering the computing power of the embedded device itself, the model compression strategy is used to tailor the redundant channels in the network to reduce the model volume and improve the detection speed. The performance test is carried out on the self-built 4 200 WK-10 electric shovel data set. The experimental results show that compared with the YOLOX network model, the average detection accuracy of the improved model reaches 95.37%, which is 1.95% higher, the detection speed is 46.1 fps, an increase of 8.4 fps, and the model size is 31.74 MB, which is reduced to 32.9% of the original. Compared with many other existing methods, the designed target detection algorithm has the advantages of high precision, small size and fast speed.

Keywords: shovel tooth; target detection; YOLOX; dilated convolution attention; CEIOU; model compression

0 引言

随着科学技术的不断进步,矿产资源的开采正向更加复杂化、自动化和智能化的方向发展^[1-2],而电铲作为矿山生产中的主要挖掘设备,在挖掘过程中铲齿与矿石直接接触会受到强烈的冲击力、摩擦力以及弯曲作用力,导致铲齿从齿座上意外松动甚至断裂,从而造成严重的经济损失和人力物力的浪费。首先,铲齿的断裂会增加电铲在挖掘作业中的摩擦阻力,使铲斗挖掘困难,进而影响挖掘作业的效率同时加快电铲的损耗^[3]。其次,由于掉落的铲齿大多是由高锰钢或合金钢制成,硬度远远高于矿石和其他材料,一旦断裂的铲齿随矿石一同卸入破碎机,会造成破碎机故障,影响整个矿山破碎生产线^[4]。因此,构建一个高精度、高实时性的铲齿断裂检测算法对于整个露天矿安全作业的正常运行有着十分重要的意义。

目前,国内外学者和研究机构一直试图在已有的视频监控系统中利用传统图像处理算法实现铲齿智能化检测。例如,Lim等^[5]通过铲齿运动过程的图像样本确定铲齿位置,利用光流法和帧差法对铲齿位置进行跟踪和修正,最后使用图像灰度特征进行铲齿缺失判断。Alma'aitah等^[6]使用Sprouts传感器网络平台对铲齿进行检测,并在铲齿中嵌入无线电力传输单元和辅助天线对已断裂的铲齿进行定位。Duan等^[7]提出利用红外热像仪捕捉铲齿信号,通过自适应阈值的方法准确检测丢失的铲齿。但传统算法往往基于图像的表层信息,需要不断更新参数以及模板匹配来获取最优特征,每个特征模板限定特定任务,无法满足铲齿断裂的快速精准检测。

随着深度学习的不断发展,计算机视觉领域取得了突破性进展,卷积神经网络成为了图像处理的重要手段,并将其引入到目标检测领域中,使得复杂工况环境下铲齿断裂快速精准检测成为了可能^[8-9]。周世禄等^[10]提出了铲齿缺失智能检测系统,使用Faster R-CNN进行铲齿目标检测,提升了铲齿检测精度。Liu等^[11]在DeepLabV3+检测算法的基础上,通过改进损失函数和添加注意力机制,完成图像的语义分割并获得铲齿轮廓信息,但由于网络模型深且参数量大,导致其难以部署到嵌入式移动设备中。因此,在保证检测精度的前提下,对卷积神经网络进行模型压缩和模型轻量化有非常重要的意义^[12]。

随着嵌入式设备在工业应用方面的需求越来越大,模型压缩和轻量化发展开始得到了人们的重视。模型压缩方法主要包括模型剪枝^[13]、知识蒸馏^[14]、低秩分解^[15]和参数量化^[16],而模型剪枝策略可以适用于复杂的网络模型中,所以得到了广泛关注。Liu等^[17]提出通道

剪枝方法,通过设定通道缩放因子来去除不重要的通道,保证网络完整性的前提下有效减少网络参数量和计算量。彭继慎等^[18]在YOLOv4网络的基础上采用通道剪枝策略,将冗余复杂的模型压缩提取为紧凑模型,从而减少模型体积,加快网络检测速度。对于轻量化模型。Redmon等^[19]提出YOLO(you only look once)网络,将目标检测过程当作回归任务,直接从输入图像中预测多个边界框。针对YOLOv1仅仅支持输入图像与训练图像分辨率相同的问题,YOLOv2^[20]改进了网络结构和位置预测机制,可以使模型适应多尺度图像输入。YOLOv3^[21]利用逻辑分类器实现了多标签分类,但由于模型的网络层数浅,导致复杂场景下小目标的识别效果不好,后续在其基础上改进的YOLOv4^[22]采用了特征金字塔网络结构,将深层特征与浅层特征融合,解决了小目标识别问题。2021年,Ge等^[23]提出了YOLOX网络模型,作为YOLO系列的典型代表,其检测精确性和实时性较YOLOv3和YOLOv4有了进一步提升,端到端部署更加灵活,模型体积和占用内存都更适用于嵌入式移动设备中。但由于电铲工作环境恶劣,会出现光照不均匀、早晚雾气大等现象,使得YOLOX网络模型在实际检测过程中检测效果不理想。而针对环境影响问题,程德强等^[24]在网络模型中加入注意力机制,提高了目标在复杂背景中的显著度。智宁等^[25]在VGG检测算法的基础上,通过优化损失函数以及锚框比,实现了煤矿图像尘雾清晰化检测。

综上所述,针对露天矿复杂工况环境下电铲铲齿松动或断裂未被及时准确地检测而导致严重的安全隐患问题,提出了一种基于改进YOLOX的电铲铲齿断裂检测方法。本文主要的贡献和创新点如下:1)针对受光照不均匀等影响导致检测效果差的问题,在特征金字塔网络加入扩张卷积注意力机制增强目标在复杂背景中的显著度;2)使用CEIOU损失函数优化网络训练过程,进而提高目标的检测精度;3)考虑嵌入式设备本身的计算能力问题,利用模型压缩策略裁剪网络中冗余通道,减少模型体积并提高检测速度。

1 YOLOX 算法

YOLOX网络主要由Inputs、Backbone、Neck以及Prediction这4部分组成,其网络结构如图1所示。Inputs由Mosaic和MixUP等数据增强方法组成以提高数据集的多样性,解决网络过拟合的问题;Backbone使用CSP(center and scale prediction)和Focus结构对输入图片不同类别的特征进行聚合并提取,同时将提取到的最后3个特征层传入Neck中进行高低层语义特征融合,进而增强高语义特征的传达能力^[26];Prediction部分采用Decouple head结构,将分类过程与回归过程分开去判断

该特征点是否为与之对应的目标,并采用无锚框和 simOTA 标签分配方法,解决了最优传输问题并降低模型参数量,使得网络的回归速度与精度得到了提升。

YOLOX 网络的基本组成主要包括:卷积、批归一化和 SiLU 激活函数 (Focus、CBS)、CSP 和 SPP 结构。其

中,Focus 结构对图片进行切片操作,得到 2 倍信息的下采样特征图^[27];CBS 结构对图片进行特征提取,同时使用 CSP 残差结构优化网络中的梯度信息,减少推理计算量,加快网络的计算速度;SPP 层对不同池化核大小的最大池化进行特征提取,提高了网络的感受野。




图 1 YOLOX 网络结构
Fig. 1 YOLOX network structure

2 改进的 YOLOX 算法

2.1 扩张卷积注意力机制

电铲在工作过程中经常会遇到光照不均匀、早晚雾气大等情况,导致目标特征不明显,通过在特征金字塔网络加入注意力模块,可以缓解环境带来的干扰从而提高检测精确率。但现有的注意力机制大多为通道或空间注意力机制,无法让网络同时注意到贡献最大的通道和贡献最大的空间。为了克服这个困难,在模型中添加通道和空间注意力模块^[28],该模块占用较少的计算量,却能

明显提升检测性能。但为了增加网络的感受野,更好地将目标和背景信息联系起来,本文将卷积层改为扩张卷积层。然而,Yu 等^[29]指出在特征图的频率高于扩张卷积的采样频率时,扩张卷积会导致网格化伪影。为了移除网格化伪影,在扩张率为 4 的卷积层后,再添加两个扩张率较小的卷积层。本文在 FPN 的上采样和下采样后分别添加 Dilated CBAM 模块去计算特征图在通道和空间位置上的权重信息,根据权重分配提高网络区分目标和背景的能力,在实际应用中取得了较好的检测效果,其结构如图 2 所示。




图 2 Dilated CBAM 结构
Fig. 2 Dilated CBAM structure

Dilated CBAM 模块首先把输入特征 F 送入通道注意力模块,该模块通过平均池化 (Avg pool) 和最大池化 (Max pool) 得到每个通道的信息,并将得到的参数通过多层感知器进行叠加,再经过 sigmoid 函数激活,得通道注意力特征 $M_c(F)$,其计算公式如式(1)所示。

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (1)$$

式中: $\sigma(\cdot)$ 表示 sigmoid 激活函数; MLP 表示多层感知器, W_0 和 W_1 分别表示隐藏层权重和输出层权重; F_{avg}^c 和 F_{max}^c 分别表示通道注意力模块的平均池化和最大池化运算。

在将特征图 F_x 送入空间注意力模块后,利用池化操作沿通道维度汇聚空间信息,生成空间特征图,再经过扩张率为 4、2 和 1 的扩张卷积计算和 sigmoid 函数激活,得到空间注意力特征 $M_s(F_x)$,其计算公式如式(2)所示。

$$M_s(F_x) = \sigma(f_4^{3 \times 3}(f_2^{3 \times 3}(f_1^{3 \times 3}(Avgpool(F_x); Maxpool(F_x)))) = \sigma(f_4^{3 \times 3}(f_2^{3 \times 3}(f_1^{3 \times 3}(F_{avg}^s; F_{max}^s)))) \quad (2)$$

式中: $f_4^{3 \times 3}$ 、 $f_2^{3 \times 3}$ 和 $f_1^{3 \times 3}$ 分别表示卷积核大小为 3×3 , 扩张率为 4、2 和 1 的扩张卷积计算; F_{avg}^s 和 F_{max}^s 分别表示空间注意力模块的平均池化和最大池化运算。

2.2 优化损失函数

YOLOX 训练过程中使用的损失函数主要包括置信度损失、分类损失和边框回归损失。其中,目标的置信度得分和分类得分采用交叉熵损失 (binary cross entropy loss) 函数计算,而边框回归损失采用 $GIOU$ 函数计算,其计算公式如式(3)所示。

$$GIOU_{Loss} = 1 - GIOU = 1 - IOU + \frac{C - (A \cup B)}{C} \quad (3)$$

式中: A 和 B 分别表示目标框与预测框, C 表示两个框的最小包围矩形, IOU 表示目标框和预测框的相交与并集之比。

由式(3)可知,当目标框和预测框相互重叠或宽、高出现对齐时, $GIOU$ 函数退化为 IOU ,此时将无法估算目标框和预测框的相对位置。 $EIOU$ 函数^[30]综合考虑了两个框的重叠部分、中心距离以及长宽比,保证训练过程中具有较好收敛速度的同时也能提高检测精度。此外笔者在 $EIOU$ 函数的基础上将两个框的左上角和右下角距离作为惩罚项考虑在内,得到新的 $CEIOU$ 函数,其原理如图 3 所示。

图 3 中, w_1 和 h_1 分别为目标框的宽、高, w_2 和 h_2 分别为预测框的宽、高; c_w 和 c_h 分别为目标框与预测框最小包围矩形的宽、高; r 和 c 分别为目标框与预测框的中心距离和对角线距离, EF 和 GH 分别为两个框的左上角和右下角距离。通过计算以上信息得到估算预测框位置




图 3 CEIOU 原理

Fig. 3 The schematic diagram of the CEIOU

的惩罚项,并从 IOU 中减去惩罚项得到 $CEIOU$ 函数, $CEIOU_{Loss}$ 的一般形式如下所示:

$$h = |h_1 - h_2| \quad (4)$$

$$w = |w_1 - w_2| \quad (5)$$

$$EIOU = IOU - \frac{r^2}{c^2} - \frac{h^2}{c_h^2} - \frac{w^2}{c_w^2} \quad (6)$$

$$CEIOU = IOU - \frac{r^2}{c^2} - \frac{h^2}{c_h^2} - \frac{w^2}{c_w^2} - \frac{EF + GH}{2 \times c} \quad (7)$$

$$CEIOU_{Loss} = 1 - CEIOU \quad (8)$$

2.3 模型剪枝

模型剪枝可分为层剪枝、通道剪枝以及权重剪枝 3 种方式。本文选用通道剪枝策略,不仅能有效压缩模型体积,同时也能最大程度上保留检测精确度。其中,通道剪枝策略主要分为 3 步:稀疏训练、通道剪枝与微调^[31]。

1) 稀疏训练

稀疏训练有助于区分重要通道以及不重要通道,为剪枝不重要通道做准备。为了实现更高效的通道修剪,通常需要设定一个指标保证模型的准确性,同时也能获得相对较高的稀疏性。在 YOLOX 网络中,每一个卷积层的后面都有一个批量归一化 (batch normalization, BN) 层,以加速模型的收敛和提高网络的泛化能力^[32]。假设 y_{in} 和 y_{out} 表示 BN 层的输入和输出,批量归一化层的转换公式如式(9)所示。

$$y_{out} = \gamma \times \frac{y_{in} - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (9)$$

式中: μ 和 σ^2 表示输入特征图的均值和方差, β 表示输入特征图的偏差, ε 为防止分母为 0 的最小因子, γ 为通道重要性的量化指标,称为通道的缩放因子。针对引进缩放因子 γ 的通道剪枝算法损失函数如式(10)所示。

$$L = L_{YOLOX} + a \sum_{\gamma \in T} f(\gamma) \quad (10)$$

式中: L_{YOLOX} 为 YOLOX 的训练损失值,第 2 项为 L1 的正则约束项。其中, $f(\gamma)$ 表示使缩放因子分布稀疏的惩罚函数,本文取 $g\gamma = |\gamma|$,而 a 起到了平衡这两个项的作用。

2) 通道剪枝与微调

由图 4 可清晰的看出,通道剪枝策略将复杂冗余的模型压缩提取为简单模型。假设 γ 的阈值设为 0.1,则将低于阈值的卷积层的输入和输出连接以及相应的权重进

行剪枝,可以很好的降低模型体积并保证模型完整性。但是当设置的修剪率过高时,会对网络进行过度修剪从而导致模型的精度大幅降低,所以还需要利用微调使修剪后的网络恢复精度。




图 4 通道剪枝策略
Fig. 4 Channel pruning strategy

2.4 改进 YOLOX 网络结构

改进后的 YOLOX 网络结构如图 5 所示,首先在特征金字塔网络的上采样和下采样后添加 Dilated CBAM 模

块,然后使用 CEIOU 损失函数代替 GIOU 损失函数优化网络的训练过程,最后使用模型压缩策略裁剪网络中冗余通道,从而获得最终的图像检测结果。




图 5 改进 YOLOX 网络结构
Fig. 5 Improved YOLOX network structure

3 实验与结果分析

实验中使用的环境配置如表 1 所示。

3.1 数据集构建

本文采用工业相机采集样本,比普通监控摄像头进光量更多,在露天微光环境下,也可以呈现出清晰的画面,同时配备角度可调节的摄像头支架和混合补光灯,便

于调整录像角度和夜间补光。本次实验共采集关键帧图像 1 200 张,其中夜间 500 张,白天 700 张,图像分辨率为 1 280×960,样本类别涵盖工作场景中的铲齿、铲斗、行人、自卸车以及巡逻车等目标,并采用传统数据增强方法对原始图像进行旋转、Mosaic 数据增强以及高斯滤波等,将数据集扩充至 4 200 张。其中,数据集的 70%作为训练样本集,20%作为验证样本集,10%作为测试样本集,部分数据集如图 6 所示。

表 1 实验环境配置

Table 1 Experiment environment configuration	
配置名称	版本参数
操作系统 GPU CPU 深度学习框架	Ubuntu20. 04LTS
	NVIDIA GeForce RTX
	3060 Ti
	Intel Core
	i5-10400F@2. 90 GHz×6
CPUs	
Pytorch	



图 6 数据集示例
Fig. 6 Dataset example

3.2 评价指标

为了对检测结果进行定量分析,本次实验将平均检测精度(*mAP*)、模型体积(model volume)以及 FPS 这 3 个指标作为衡量标准进行评价。其中 *mAP* 的计算公式如式(11)所示。

$$mAP = \frac{\sum_{n=1}^n AP(n)}{n} \times 100\%$$

(11)

式中: *n* 为检测类别数,本文 *n* 取 9; *mAP* 表示所有类别检测精度(*AP*)的平均值,该值越大,检测精度就越高。其中, *AP* 在数值上等于 *P-R* 曲线与横纵坐标轴所围成的面积。*P*、*R* 的计算公式如下所示:

$$P = \frac{TP}{TP + FP} \times 100\%$$

(12)

$$R = \frac{TP}{TP + FN} \times 100\%$$

(13)

式中: *TP*、*FP*、*FN* 分别表示真阳性、假阳性以及假阴性; *P* 为精确度, *R* 为召回率。

3.3 验证模型改进有效性

1) 训练与结果分析

为防止训练过程中出现过拟合、欠拟合、超调以及梯度爆炸等现象,保证参数设置的适应性及合理性,设定初始学习率为 1×10^{-3} ,动量系数为 0.949,迭代次数为 4 000 次,且分别在迭代 3 200 次和 3 600 次时改变学习率为 1×10^{-4} 和 1×10^{-5} ,网络训练的损失函数值变化曲线如图 7

所示。由图可知,YOLOX 的损失值在迭代 3 200 次时才逐渐降低到 1.2,最终稳定至 1 附近,而 YOLOX-DC (YOLOX-Dilated CBAM-CEIOU)的损失值低且收敛速度快,在 1 800 次迭代处的损失值稳定至 0.7 左右,模型呈现收敛趋势,由此可看出 YOLOX-DC 模型达到了较好的训练效果。




图 7 损失函数值变化曲线
Fig. 7 Change curve of loss function value

在模型训练完成后,分别将测试样本集输入到各模型中进行测试,对比 YOLOX (baseline)、添加 Dilated CBAM 的 YOLOX-D、引入 CEIOU 损失函数的 YOLOX-C 以及二者都引入的 YOLOX-DC 网络模型的检测结果,进而验证模型改进的有效性,其实验结果如表 2 所示。

Table 2 Comparison of experimental results			
模型名称	mAP/%	模型体积/MB	FPS
YOLOX	93.42	96.46	37.7
YOLOX-D	95.44	102.28	35.3
YOLOX-C	94.71	99.12	36.6
YOLOX-DC	96.43	103.82	34.5

从表 2 可清晰的看出,当引入 Dilated CBAM 模块和 CEIOU 损失函数后,YOLOX-DC 的模型体积增加了 7.36 MB,检测速度降低了 3.2 fps,但检测精度提升了 3.01%,能够确保模型在光照不均匀等环境下也能达到较好的检测效果。

2) 模型压缩实验

(1) 稀疏化训练

在初始训练环境相同的条件下,设置惩罚因子 b_h 分别为 0.01、0.005、0.001 以及 0.0001,通过对比稀疏化训练过程中模型性能来选择最优的惩罚因子。图 8 为不同惩罚因子下的 mAP 曲线,从图中可以看出,当惩罚因子 $b_h = 0.001$ 时,YOLOX-CD 模型检测性能达到最优,故选取 $b_h = 0.001$ 作为最终通道稀疏化训练的惩罚因子。




图 8 不同惩罚因子下的 mAP 曲线

Fig. 8 mAP curve under different penalty factors

(2) 模型裁剪与微调

为了进一步提高模型的检测性能,本文对 YOLOX-DC 模型进行了裁剪,且裁剪率分别设置为 0.5、0.7 和 0.9。不同裁剪率模型的性能如表 3 所示。

表 3 不同修剪率的模型性能对比

Table 3 Model performance comparison with different pruning rates

模型名称	mAP/%	模型体积/MB	FPS
YOLOX	93.42	96.46	37.7
YOLOX-DC	96.43	103.82	34.5
YOLOX-DC-0.5	96.24	51.64	41.7
YOLOX-DC-0.7	95.37	31.74	46.1
YOLOX-DC-0.9	56.61	7.84	51.5

从表 3 中可以看出,随着裁剪率的增加,模型体积和预测时间都在不断减少。相较于 YOLOX 模型,YOLOX-DC-0.7 的平均检测精度提高了 1.95%,检测速度提升了 8.4 fps,模型体积减少到 YOLOX 模型的 32.9%。实验结果表明,模型压缩方法可以在保证高精度的前提下,减少模型体积同时加快检测速度。为了更加直观的体现出本文算法对铲齿断裂快速精准检测的效果,在测试样本集中分类选取样本开展多组对比实验,实验结果如图 9 所示。

图 9(a) 为电铲正常工作场景下上、下两路图像检测结果,包括上视挖掘、下视挖掘、上视装车和下视装车。

从图中可以看出,本文算法能够有效对铲齿、铲斗以及矿车等目标进行检测,且框定范围准确度较高。图 9(b) 为电铲工作过程中可能遇见的危险场景下检测结果,包括遮挡检测、断齿检测、车辆入侵和人员入侵。从图中可以看出,本文提出的算法不仅能够检测铲齿是否断裂,还能对入侵车辆及人员进行识别,有效预防了危险事故的发生。图 9(c) 为复杂工况场景下图像的检测结果,从图中可以看出,即使在光照不均匀、早晚雾气大等环境下,改进后的算法依然可以很好的检测到小的、弱的和遮挡的目标。

本文以 WK-35 型电铲数据集为例进行迁移实验,实验从数据集中随机选取不同场景下的样本进行测试,测试结果如图 10 所示。对未经训练的新样本数据而言,YOLOX 模型不能准确识别目标,而改进后的模型能够实现较好的检测效果,证明了本文算法具有较好的泛化性能。

3.4 不同算法对比实验

为进一步验证本文算法的优势,将其与 Faster R-CNN、YOLOv3、YOLOv4 和 YOLOv5 这 4 种经典目标检测算法在相同数据集和训练环境下进行客观实验对比,对比结果如图 11 所示。

由图 11 可知,本文算法的 P-R 曲线位于所有曲线的最上端,模型性能要优于其他 4 种算法。将以上实验结果列入表 4 中可看出,本文算法较 Faster R-CNN、YOLOv3、YOLOv4 以及 YOLOv5 这 4 种算法在 mAP 上分别提高了 4.20%、7.81%、5.49% 和 3.72%,同时模型体积更小、检测速度更快,适合部署在嵌入式移动设备中。综合各方面性能,表明本文算法可以满足复杂工况环境下电铲铲齿断裂快速精准检测的要求。

表 4 不同算法参数对比

Table 4 Comparison of parameters of different algorithms

模型名称	mAP/%	模型体积/MB	FPS
Faster R-CNN	91.17	522.91	11.8
YOLOv3	87.56	236.20	30.1
YOLOv4	89.88	245.00	34.6
YOLOv5	91.65	89.54	40.2
本文算法	95.37	31.74	46.1

3.5 铲齿断裂判别算法

目标检测算法仅能检测到目标的类别、个数以及边框位置,而当铲齿发生断裂时,检测系统需要准确判断断裂铲齿的位置,并将断裂位置在人机交互界面中进行显示。但由于铲齿检测系统处于动态作业过程,仅通过单张图片进行模板匹配来判定铲齿断裂位置是不可行的,鉴于每个铲齿型号一致且形状基本相同,故以铲齿检测




图 9 本文算法在测试样本集上的检测结果

Fig. 9 The detection results of the algorithm in this paper on the test sample set



图 10 迁移实验检测结果对比

Fig. 10 Comparison of migration test results

框的高度 b_h 为基础设计铲齿断裂判别算法,其具体工作流程如图 12 所示。

对铲齿断裂进行判别时,可通过计算所有铲齿框高度 b_h 的标准差 S_{Nh} 进行分析。若 S_{Nh} 值较小,则说明铲齿高度基本相同;若 S_{Nh} 值较大,则说明某个铲齿的高度较其他铲齿高度有较大差别,然后将此框高度和其他框高度均值之比作为铲齿断裂判别依据,记为 P_h 。当 $P_h \leq 75\%$ 时,铲齿断裂帧数 $T_h + 1$,直到 T_h 不低于铲齿断裂帧

数阈值 T_{miss} 时,表明铲齿发生断裂。其中, S_{Nh} 和 P_h 的计算公式如下所示:

$$S_{Nh} = \sqrt{\frac{1}{n_{tooth}} \sum_{i=1}^{n_{tooth}} (bh_i - \overline{bh})^2} \quad (14)$$

$$P_h = \frac{bh_j(n_{tooth} - 1)}{\left(\sum_{i=1}^{n_{tooth}} bh_i\right) - bh_j} \times 100\% \quad (15)$$

式中: bh_i 表示第 i 个铲齿检测框的高度, $\overline{bh}$ 表示所有铲




图 11 不同算法的 P-R 曲线图

Fig. 11 P-R curves of different algorithms




图 12 铲齿断裂判别流程

Fig. 12 Flow chart of judgment for tooth breaking

齿检测框的平均高度, b_{h_j} 表示断裂铲齿检测框的高度。

4 铲齿检测实验分析

4.1 检测系统搭建

为了验证所构建模型对电铲铲齿检测的可行性,在内蒙古某大型露天矿进行现场实验。经现场考察,综合权衡生产安全性、硬件可靠性、系统稳定性和布局合理性等,搭建铲齿智能检测系统平台,其工作流程如图 13 所示。由图可知,铲齿智能检测系统主要由图像采集模块、以太网通信模块、检测模块以及显示模块 4 个部分组成。

首先在电铲大臂的天轮下方以及回转平台上安装上、前视摄像头,采用双监控点互补的方式最大程度上采集图像信息,然后通过以太网将图像信息传输至嵌入式 Xavier 处理器进行基于深度学习算法的目标检测,最后将检测结果经 UDP 协议传输到工业触摸一体机进行结果显示。

4.2 铲齿检测实验

铲齿智能检测系统搭建完成后,分别在 WK-10 和 WK-35 型电铲进行现场测试实验。由图 14(a) 可知,当铲齿出现断裂时,本文算法可以快速精准检测同时将断裂位置在人机交互界面进行显示。由图 14(b) 可知,在未经训练的 WK-35 型电铲上本文算法也能实现较好的检测效果,验证了该方法的可行性与实用性。

5 结 论

针对露天矿复杂工况环境下电铲铲齿松动或断裂未被及时准确地检测而导致严重的安全隐患问题,提出了一种基于改进 YOLOX 的电铲铲齿断裂检测方法。通过对内蒙古某大型露天矿电铲工作场景进行现场实验,得出以下结论:

1) 添加扩张卷积注意力以及优化检测网络损失函数解决了复杂环境中目标显著度弱导致其难以准确检测的问题;利用模型压缩策略裁剪网络中冗余通道,在保证模型完整性的基础上显著提高网络检测速度,减小模型体积。实验结果表明改进后模型的平均检测精度达到了 95.37%,提高了 1.95%,检测速度为 46.1 fps,提升了 8.4 fps,模型体积为 31.74 MB,减少到原来的 32.9%。

2) 与 Faster R-CNN、YOLOv3、YOLOv4 及 YOLOv5 等算法进行对比实验结果表明,本文算法在检测精度、速度和模型体积方面展现出了明显的优势,适合部署在嵌入式移动设备端进行检测和计算。

3) 在露天矿现场实验中,通过搭建铲齿智能检测系统对改进的 YOLOX 网络进行训练和测试,验证了该方法的可行性与实用性,为智慧矿山和矿山开采智能化的发展提供了理论依据和技术方案。

参考文献

- [1] 王国法,赵国瑞,任怀伟.智慧煤矿与智能化开采关键核心技术分析[J].煤炭学报,2019,44(1):34-41.
WANG G F, ZHAO G R, REN H W. Analysis of key core technologies of smart coal mine and intelligent mining [J]. Journal of Coal, 2019, 44(1):34-41.
- [2] 谭章禄,马营营,郝旭光,等.智慧矿山标准发展现状及路径分析[J].煤炭科学技术,2019,47(3):27-34.
TAN ZH L, MA Y Y, HAO X G, et al. Development status and path analysis of smart mine standards [J].




图 13 铲齿智能检测系统

Fig. 13 Intelligent detection system of shovel teeth




图 14 电铲现场测试实验

Fig. 14 Field test experiment of shovel

Coal Science and Technology, 2019, 47(3): 27-34.

[3] AKTER A Y, BASAK H. Design and analysis of biomimetics based excavator bucket and tooth [J]. Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering, 2022, 236(3): 1167-1175.

[4] JI SH F, LI W, ZHANG B, et al. Bucket teeth detection based on faster region convolutional neural network [J]. IEEE Access, 2021, 9: 17649-17661.

[5] LIM S N, SOARES J, ZHOU N. Tooth guard: A vision system for detecting missing tooth in rope mine shovel [C]. 2016 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2016: 1-7.

[6] ALMA'AITAH A, HASSANEIN H S. Utilizing sprouts WSN platform for equipment detection and localization in harsh environments [C]. 39th Annual IEEE Conference on Local Computer Networks Workshops. IEEE, 2014: 777-783.

[7] DUAN Y X, DU W H, ZENG ZH Q, et al. Electric bucket teeth missing detection method based on machine vision [J]. Industry and Mine Automation, 2018, 44(7): 75-80.

[8] 毛向向,王红军,韩凤霞,等. 基于深度卷积神经网络的机电系统故障分类识别方法 [J]. 电子测量与仪器学报, 2021, 35(2): 87-93.

MAO X X, WANG H J, HAN F X, et al. Fault classification and identification method of electromechanical system based on deep convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 87-93.

[9] 曹红燕,沈小林,刘长明,等. 改进的YOLOv3的红外目标检测算法 [J]. 电子测量与仪器学报, 2020, 34(8): 188-194.

CAO H Y, SHEN X L, LIU CH M, et al. Infrared target detection algorithm of improved YOLOv3 [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(8): 188-194.

[10] 周世禄,杨小彬,王逍遙,等. 基于深度学习电铲铲齿缺失智能监测系统研究 [J]. 煤炭科学技术, 2020, 48(S1): 119-124.

ZHOU SH L, YANG X B, WANG X Y, et al. Research on intelligent monitoring system for tooth loss of electric shovel based on deep learning [J]. Coal Science and Technology, 2020, 48(S1): 119-124.

[11] LIU X B, QI X L, JIANG Y M. Electric shovel teeth

- missing detection method based on deep learning[J]. Computational Intelligence and Neuroscience, 2021, 2021.
- [12] ZHENG J CH, SUN SH D, ZHAO SH J. Fast ship detection based on lightweight YOLOv5 network[J]. IET Image Processing, 2022, 16(6): 1585-1593.
- [13] 徐志强, 吕子奇, 王卫东, 等. 煤矸智能分选的机器视觉识别方法与优化[J]. 煤炭学报, 2020, 45(6): 2207-2216.
- XU ZH Q, LYU Z Q, WANG W D, et al. Machine vision recognition method and optimization of intelligent coal gangue sorting[J]. Journal of Coal, 2020, 45(6): 2207-2216.
- [14] XING ZH Q, CHEN X, PANG F Q. DD-YOLO: An object detection method combining knowledge distillation and differentiable architecture search[J]. IET Computer Vision, 2022(5): 16.
- [15] PRATUSEVICH M. Deep learning approximation: Zero-shot neural network speedup[J]. arXiv preprint arXiv: 1806.05779, 2018.
- [16] 张帆, 黄赞, 方子苗, 等. 卷积神经网络的损失最小训练后参数量化方法[J]. 通信学报, 2022, 43(4): 114-122.
- ZHANG F, HUANG Y, FANG Z ZH, et al. Post training parameter quantification method for convolutional neural network with minimal loss[J]. Journal on Communications, 2022, 43(4): 114-122.
- [17] LIU ZH, LI J G, SHEN ZH Q, et al. Learning efficient convolutional networks through network slimming[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2736-2744.
- [18] 彭继慎, 孙礼鑫, 王凯, 等. 基于模型压缩的 ED-YOLO 电力巡检无人机避障目标检测算法[J]. 仪器仪表学报, 2021, 42(10): 161-170.
- PENG J SH, SUN L X, WANG K, et al. ED-YOLO power inspection UAV obstacle avoidance target detection algorithm based on model compression[J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 161-170.
- [19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Computer Vision & Pattern Recognition, IEEE, 2016.
- [20] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2017.
- [21] 陈国平, 彭之玲, 黄超意, 等. 基于改进 YOLOv3-Tiny 的毫米波图像目标检测[J]. 电子测量技术, 2021, 44(21): 163-167.
- CHEN G P, PENG ZH L, HUANG CH Y, et al. Millimeter wave image object detection based on improved YOLOv3-Tiny[J]. Electronic Measurement Technology, 2021, 44(21): 163-167.
- [22] 史雨馨, 朱继杰, 凌志刚. 基于特征增强 YOLOv4 的无人机检测算法研究[J]. 电子测量与仪器学报, 2022, 36(7): 16-23.
- SHI Y X, ZHU J J, LING ZH G. Research on UAV detection algorithm based on feature enhancement YOLOv4[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7): 16-23.
- [23] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021[J]. arXiv preprint arXiv: 2107.08430, 2021.
- [24] 程德强, 陈杰, 寇旗旗, 等. 融合层次特征和注意力机制的轻量化矿井图像超分辨率重建方法[J]. 仪器仪表学报, 2022, 43(8): 73-84.
- CHENG D Q, CHEN J, KOU Q Q, et al. Super-resolution reconstruction method of lightweight mine image by combining hierarchical features and attention mechanism[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 73-84.
- [25] 智宁, 毛善君, 李梅, 等. 基于深度融合网络的煤矿图像尘雾清晰化算法[J]. 煤炭学报, 2019, 44(2): 655-666.
- ZHI N, MAO SH J, LI M, et al. Dust and fog clarity algorithm for coal mine image based on deep fusion network[J]. Journal of China Coal Society, 2019, 44(2): 655-666.
- [26] 卢进南, 刘扬, 王连捷, 等. 基于改进 Mask Scoring R-CNN 的铲齿磨损检测研究[J]. 工程设计学报, 2022, 29(3): 309-317.
- LU J N, LIU Y, WANG L J, et al. Research on shovel tooth wear detection based on improved Mask Scoring R-CNN[J]. Journal of Engineering Design, 2022, 29(3): 309-317.
- [27] 张麒麟, 林清平, 肖蕾. 改进 YOLOv5 的航拍图像识别算法[J]. 长江信息通信, 2021, 34(3): 73-76.
- ZHANG Q L, LIN Q P, XIAO L. Improved YOLOv5 aerial image recognition algorithm[J]. Changjiang Information and Communication, 2021, 34(3): 73-76.
- [28] 郝帅, 张旭, 马旭, 等. 基于 CBAM-YOLOv5 的煤矿输送带异物检测[J]. 煤炭学报, 2022, 47(11): 4147-4156.
- HAO SH, ZHANG X, MA X, et al. Detection of foreign objects in coal mine conveyor belt based on CBAM-YOLOv5[J]. Journal of Coal, 2022, 47(11): 4147-4156.
- [29] YU F, KOLTUN V, FUNKHOUSER T. Dilated residual

networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 472-480.

- [30] AHMED F, TARLOW D, BATRA D. Optimizing expected intersection-over-union with candidate-constrained CRFs [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1850-1858.
- [31] 黄文斌, 陈仁文, 袁婷婷. 改进 YOLOv3-SPP 的无人机目标检测模型压缩方案 [J]. 计算机工程与应用, 2021, 57(21): 165-173.
- HUANG W B, CHEN R W, YUAN T T. Improved YOLOv3-SPP UAV target detection model compression scheme [J]. Computer Engineering and Applications, 2021, 57(21): 165-173.
- [32] CHEN SH Q, ZHAN R H, WANG W, et al. Learning slimming SAR ship object detector through network pruning and knowledge distillation [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 14: 1267-1282.

作者简介



卢进南, 2014 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为机械电子工程、人工智能和机器学习等。

E-mail: ljn-22@163.com

Lu Jinnan received his Ph. D. from Liaoning University of Engineering and Technology in 2014. Now he is an associate professor at Liaoning University of Engineering and Technology. His main research interests include mechatronic engineering, artificial intelligence and machine learning, etc.



刘扬 (通信作者), 2020 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为机器视觉与深度学习。

E-mail: 121185350@qq.com

Liu Yang (Corresponding author)

received his B. Sc. degree from Liaoning University of Engineering and Technology in 2020. Now he is a M. Sc. candidate at Liaoning University of Engineering and Technology. His main research interests include machine vision and deep learning.



王连捷, 2019 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为人工智能与机械装备智能化。

E-mail: liuyang85350@163.com

Wang Lianjie received his B. Sc. degree from Liaoning University of Engineering and Technology in 2019. Now he is a M. Sc. candidate at Liaoning University of Engineering and Technology. His main research interests include artificial intelligence and mechanical equipment intelligence.



黎洛, 2021 年于湖南理工学院获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为系统建模与机电液系统仿真。

E-mail: liluo3311329670@163.com

Li Luo received his B. Sc. degree from Hunan Institute of Technology in 2021. Now he is a M. Sc. candidate at Liaoning University of Engineering and Technology. His main research interests include system modeling and electromechanical and hydraulic system simulation.