

文章编号:1671-251X(2021)12-0075-06

DOI:10.13272/j.issn.1671-251x.2021030075

# 融合轻量级网络和双重注意力机制的煤块检测方法

叶鸥<sup>1</sup>, 窦晓熠<sup>1</sup>, 付燕<sup>1</sup>, 邓军<sup>2</sup>

(1. 西安科技大学 计算机科学与技术学院, 陕西 西安 710054;

2. 西安科技大学 安全科学与工程学院, 陕西 西安 710054)



扫码移动阅读

**摘要:**针对现有煤矿井下带式输送机上煤块检测方法存在检测精度低、检测速度慢等问题,提出了一种融合轻量级网络和双重注意力机制的改进 YOLOv4 模型,并将其应用于带式输送机煤块检测。改进 YOLOv4 模型采用 K-means 聚类算法重新聚类先验框,使先验框更适应检测目标尺寸;通过引入 MobileNet 轻量级网络模型改进主干网络结构,以减少模型的参数量和计算量,提高检测速度;嵌入具有双重注意力机制的卷积块注意模块,用于提高模型对目标特征的敏感度,抑制干扰信息,提高目标检测精度。实验结果表明,改进 YOLOv4 模型能准确检测出不同尺寸的煤块;相较于 YOLOv4 模型,改进 YOLOv4 模型权重文件减少了 36.46%,精确率提高了 2.16%,召回率提高了 20.4%,平均精度均值提高了 14.37%,漏检率降低了 16%,检测速度提升了 19 帧/s,处理单张图像耗时减少了 1.31 s,提高了煤块检测精度和检测速度。

**关键词:**带式输送机;煤块检测;目标检测;轻量级网络;双重注意力机制;YOLOv4

中图分类号:TD528.1 文献标志码:A

Coal block detection method integrating lightweight network and dual attention mechanism

YE Ou<sup>1</sup>, DOU Xiaoyi<sup>1</sup>, FU Yan<sup>1</sup>, DENG Jun<sup>2</sup>

(1. College of Computer Science and Technology, Xi'an University of Science and Technology,

Xi'an 710054, China; 2. College of Safety Science and Engineering, Xi'an University of

Science and Technology, Xi'an 710054, China)

**Abstract:** In order to solve the problems of low detection precision and slow detection speed of existing coal block detection methods on belt conveyor in underground coal mine, an improved YOLOv4 model integrating lightweight network and dual attention mechanism is proposed, and it is applied to coal block detection of belt conveyor. The improved YOLOv4 model uses K-means clustering algorithm to re-cluster the prior frames, so that the prior frames are more suitable for the size of the detected target. The model improves the backbone network structure by introducing the MobileNet lightweight network model to reduce the amount of model parameters and calculations, and improve the detection speed. A convolution block attention module with dual attention mechanism is embedded to improve the sensitivity of the model to target characteristics, suppress interference information and improve the precision of target detection. The experimental results show that the improved YOLOv4 model can detect coal blocks of different sizes accurately. Compared with the YOLOv4 model, the improved YOLOv4 model weight file is reduced by 36.46%, the accuracy rate is increased by 2.16%, the recall rate is increased by 20.4%, the average

**收稿日期:**2021-03-23;**修回日期:**2021-12-19;**责任编辑:**盛男,郑海霞。

**基金项目:**陕西省自然科学基金项目(2018JQ5095);中国博士后科学基金项目(2020M673446)。

**作者简介:**叶鸥(1984—),男,陕西西安人,讲师,博士,主要研究方向为数据质量评价、视频检索、跨媒体语义解析和知识工程等,E-mail: oye0928@xust.edu.cn。通信作者:窦晓熠(1996—),女,陕西咸阳人,硕士研究生,研究方向为计算机视觉,E-mail: 823962874@qq.com。

**引用格式:**叶鸥,窦晓熠,付燕,等.融合轻量级网络和双重注意力机制的煤块检测方法[J].工矿自动化,2021,47(12):75-80.

YE Ou, DOU Xiaoyi, FU Yan, et al. Coal block detection method integrating lightweight network and dual attention mechanism[J]. Industry and Mine Automation, 2021, 47(12): 75-80.

accuracy is increased by 14.37%, the missed detection rate is decreased by 16%, the detection speed is increased by 19 frames/s, the processing time for a single image is reduced by 1.31 s, which improves the detection precision and speed of coal block detection.

**Key words:** belt conveyor; coal block detection; target detection; lightweight network; dual attention mechanism; YOLOv4

0 引言

随着煤矿井下带式输送机运输距离、运载量不断提高,带式输送机可能会出现运转停止或缓慢、空载等异常情况<sup>[1]</sup>,若不及时发现,易造成安全事故和经济损失。通过对带式输送机上煤块进行目标跟踪检测,可有效反映带式输送机运行状态<sup>[2]</sup>。

目前带式输送机目标检测方法包括传统目标检测和深度学习目标检测 2 类。传统目标检测方法<sup>[3-6]</sup>在对输入图像进行预处理的基础上,先利用滑动窗口方式对图像进行候选区域筛选;之后采用 SIFT (Scale-Invariant Feature Transform, 尺度不变特征变换)、HOG (Histogram of Gradient, 梯度直方图)和 DPM (Deformable Parts Model, 可变形组件模型)等图像特征描述子,对候选区域进行图像特征抽取<sup>[7]</sup>;最后利用分类算法模型对提取的特征进行分类识别。然而,该方法需要人工设计特征,对应用环境要求较为苛刻,较难满足实际需求。深度学习目标检测方法识别率较高且鲁棒性强,在带式输送机目标检测方面得到快速推广。文献<sup>[8]</sup>提出了基于 Faster - RCNN (Region Convolutional Neural Networks, 区域卷积神经网络)的输送带异物识别方法,引入置信度惩罚函数筛选最佳候选框,可以获得较高的检测精度。文献<sup>[9]</sup>以 SSD(Single Shot MultiBox Detector, 单步多框检测器)模型为基础框架,通过替换损失函数及优化默认锚框比例等方式,提高煤矿输送带异物的检测精度。文献<sup>[10]</sup>在 YOLOv3 模型的基础上,采用 Focal Loss 函数替换交叉熵损失函数,并通过调节最佳超参数来解决带式输送机非煤异物样本不平衡性问题,提高了模型检测性能。文献<sup>[11]</sup>提出了一种改进 YOLOv3 模型,设计了 DarkNet22-DS 网络作为主干特征提取网络,融合 BiFPN(Bidirectional Feature Pyramid Network, 双向特征金字塔网络)模型,采用完全交并比作为目标框的回归损失函数,实现了带式输送机异物检测精度和时效性的提升。然而,由于煤矿井下图像质量较差,煤块间边缘特征不明显,导致煤块检测精度低,且现有识别模型参数规模大,导致运行速度慢<sup>[12-13]</sup>。本文提出了一种融合轻量级网络和双重注意力机制的改进 YOLOv4 模型,

并将其应用于带式输送机煤块检测。在 YOLOv4 模型的基础上,引入 MobileNet 轻量级网络模型<sup>[14]</sup>,改进 YOLOv4 模型的主干网络结构,减少 YOLOv4 模型的参数量和计算量,并嵌入具有双重注意力机制的 CBAM (Convolutional Block Attention Module, 卷积块注意模块)<sup>[15]</sup>,提高 YOLOv4 模型对目标特征的敏感度,实现煤矿井下带式输送机煤块的实时检测。

1 改进 YOLOv4 模型

改进 YOLOv4 模型融合了轻量级网络和双重注意力机制,其总体架构如图 1 所示。利用 K-means 聚类算法重新聚类先验框<sup>[16]</sup>,根据给定的数据集样本,通过距离计算将相似样本的锚框归为一类,得到适应数据集的锚框,从而提高模型学习能力。引入 MobileNet 轻量级网络模型,替换 YOLOv4 模型的主干网络 CSPDarknet53,可在不损失精度的前提下,有效减少模型参数量,提高模型检测速度。引入具有双重注意力机制的 CBAM,通过关注通道和空间双重信息,扩大网络感知范围,使网络对待检测目标更敏感,以减少因图像质量较差导致的漏检和因煤块间边缘特征不明显导致的误检。




图 1 融合轻量级网络和双重注意力机制的改进 YOLOv4 模型总体架构  
Fig. 1 Improved YOLOv4 model overall framework integrating lightweight network and dual attention mechanism

1.1 K-means 重新聚类

在利用 YOLOv4 模型进行目标检测的过程中,待检测物体预先生成的锚框尺寸较难完全适用于不同的检测对象,会影响网络训练及学习的泛化能力。首先在 COCO 公共数据集上通过 K-means 聚类分析得到 9 组初始化的锚框尺寸,分别为 (12, 16), (19, 36), (40, 28), (36, 75), (76, 55), (72, 146), (142, 110), (192, 243), (459, 401), 用于检测不同尺寸的目标 (25~100 mm 中块煤, >100 mm 大块煤)。由于物体属性不同,煤块尺寸与公共数据集上物体尺寸相差较大,不能直接使用初始化的锚框尺寸。所以,通过 K-means 算法重新聚类, K 值 (K=9) 不变,通过在包含大量中块煤和大块煤的实验数据集上进行聚类分析,所得锚框尺寸分别为 (11, 12), (14, 16), (19, 16), (22, 23), (27, 38), (30, 27), (36, 51), (42, 31), (72, 62)。

1.2 YOLOv4 模型主干网络改进

YOLOv4 模型的主干网络采用 CSPDarknet53<sup>[17]</sup>, 使用 SPP(Spatial Pyramid Pooling, 空间金字塔池) 和 PANet 模块进行特征融合, 可有效提取视频图像特征信息。但是, 由于该网络具有大量参数, 使得模型检测精度和速度不理想。为了满足煤块检测的速度要求, 引入 MobileNet 轻量级网络模型, 替换 YOLOv4 模型的主干网络, 如图 2 所示。传统标准卷积和深度可分离卷积如图 3 所示。改进 YOLOv4 模型的主干网络采用深度可分离卷积层, 将传统标准卷积层分成深度卷积和点卷积 2 种卷积方式, 通过深度卷积和点卷积提取特征, 并输出 3 个尺寸的特征图用于检测不同尺度大小的煤块。

| 层的名称                 | 过滤器尺寸                     | 过滤器尺寸     | 输出尺寸          |
|----------------------|---------------------------|-----------|---------------|
| input_1              |                           | 0         | (416,416,3)   |
| Conv1                | 3×3×3×32                  | 864       | (208,208,32)  |
| Conv_dw_1            | 3×3×32 dw                 | 288       | (208,208,32)  |
| Conv_pw_1            | 1×1×32×64                 | 2 048     | (208,208,64)  |
| Conv_dw_2            | 3×3×64 dw                 | 576       | (104,104,64)  |
| Conv_pw_2            | 1×1×64×128                | 8 192     | (104,104,128) |
| Conv_dw_3            | 3×3×128 dw                | 1 152     | (104,104,128) |
| Conv_pw_3            | 1×1×128×128               | 16 384    | (104,104,128) |
| Conv_dw_4            | 3×3×128 dw                | 1 152     | (52,52,128)   |
| Conv_pw_4            | 1×1×128×256               | 32 768    | (52,52,256)   |
| Conv_dw_5            | 3×3×256 dw                | 2 304     | (52,52,256)   |
| Conv_pw_5            | 1×1×256×256               | 65 536    | (52,52,256)   |
| Conv_dw_6            | 3×3×256 dw                | 2 304     | (26,26,256)   |
| Conv_pw_6            | 1×1×256×512               | 131 072   | (26,26,512)   |
| (Conv_dw, Conv_pw)×5 | 3×3×512 dw<br>1×1×512×512 | 262 144   | (26,26,512)   |
| Conv_dw_12           | 3×3×512 dw                | 4 608     | (13,13,512)   |
| Conv_pw_12           | 1×1×512×1 024             | 524 288   | (13,13,1 024) |
| Conv_dw_13           | 3×3×1 024 dw              | 9 216     | (13,13,1 024) |
| Conv_pw_13           | 1×1×1 024×1 024           | 1 048 576 | (13,13,1 024) |

图 2 改进 YOLOv4 模型主干网络结构

Fig. 2 Improved YOLOv4 model backbone network structure




图 3 传统标准卷积和深度可分离卷积

Fig. 3 Traditional standard convolution and depth separable convolution

假设卷积核大小为  $S \times S$ , 个数为  $R$ , 输入特征图大小为  $F_R \times F_R$ , 输入输出的特征图通道数分别为  $U$  和  $Y$ , 且输入输出的特征图尺寸相同, 则传统标准卷积的计算量为

$$Z_1 = S \times S \times F_R \times F_R \times U \times Y \quad (1)$$

当使用深度可分离卷积层时, 点卷积的计算量为

$$Z_2 = F_R \times F_R \times 1 \times 1 \times U \times Y \quad (2)$$

深度卷积计算量为

$$Z_3 = S \times S \times F_R \times F_R \times U \quad (3)$$

因此深度可分离卷积计算量为

$$Z_4 = S \times S \times F_R \times F_R \times U + F_R \times F_R \times 1 \times 1 \times U \times Y \quad (4)$$

深度可分离卷积计算量与传统标准卷积计算量之比为

$$\frac{Z_4}{Z_1} = \frac{1}{Y} + \frac{1}{S^2} \quad (5)$$

当输入图像大小为  $416 \times 416$  时, 输出的  $13 \times 13 \times 1 024$  尺寸特征图感受野较大, 可用于检测较大煤块; 输出的  $26 \times 26 \times 512$  尺寸特征图感受野适中, 可用于检测中等大小的煤块; 输出的  $52 \times 52 \times 256$  特征图感受野较小, 可用于检测较小煤块。在不损失精度的同时, 卷积计算量小, 参数少, 提高了检测速度。

1.3 具有双重注意力机制的 CBAM

CBAM 结合特征图的通道和空间 2 种信息, 在不改变特征图大小的前提下, 使模型对目标信息的感知能力更强, 可抑制无效信息带来的干扰。为提取更加丰富的待检测目标的高层语义特征, 嵌入具有双重注意力机制的 CBAM, 如图 4 所示。首先, 将池化的通道数设置为输入特征图的通道数, 计算特征图的平均池化和最大池化 2 个空间信息, 利用 MLP(Multilayer Perceptron, 多层感知机) 对平均

池化和最大池化 2 个空间信息进行空间维数压缩,得到 2 个特征向量,并对其进行求和,进一步完善检测目标的特征表示。然后,经过激活函数  $\sigma(\cdot)$  获得通道注意力权重系数  $W_c$ , 通过与原输入特征图  $G_D$  相乘得到新特征图  $G'_D$ , 分别针对新特征图  $G'_D$  计算平均池化和最大池化,并将不同池化操作后的向量进行拼接。将拼接后的特征向量输入卷积层,通过激活函数  $\sigma(\cdot)$  得到空间注意力权重系数  $W_s$ , 使网络特征学习更专注于带式输送机上煤块

特征。最后,将  $W_s$  与新特征图  $G'_D$  相乘,得到最终特征图  $G_0$ 。

$$W_c(G_D) = \sigma(g(y(G_D)) + g(x(G_D))) \quad (6)$$

$$G'_D = W_c(G_D) \otimes G_D \quad (7)$$

$$W_s(G'_D) = \sigma(f^{d \times d}(y(G'_D); x(G'_D))) \quad (8)$$

$$G_0 = W_s(G'_D) \otimes G'_D \quad (9)$$

式中:  $g(\cdot)$  为池化操作后的向量通过 MLP 的输出;  $y(\cdot)$  为平均池化函数;  $x(\cdot)$  为最大池化函数;  $f^{d \times d}$  为尺寸为  $d \times d$  的卷积层操作。




图 4 具有双重注意力机制的 CBAM 结构

Fig. 4 CBAM structure with dual attention mechanism

#### 1.4 损失函数

融合轻量级网络和双重注意力机制的改进 YOLOv4 模型的损失函数  $L$  由边界框位置损失  $L_{CIou}$ 、置信度损失  $L_{conf}$  和分类损失  $L_{cls}$  3 个部分构成。

$$L = L_{CIou} + L_{conf} + L_{cls} \quad (10)$$

$$L_{CIou} = 1 - I(A, B) + \frac{\rho^2(A_{ctr}, B_{ctr})}{m^2} + \alpha \quad (11)$$

$$\alpha = \frac{\nu}{[1 - I(A, B)] + \nu} \quad (12)$$

$$\nu = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right) \quad (13)$$

$$L_{conf} = \sum_{i=0}^{Q^2} \sum_{j=0}^E T_{ij}^{obj} [\bar{C}_i \ln(C_i) + (1 - \bar{C}_i) \ln(1 - \bar{C}_i)] + \lambda_{noobj} \sum_{i=0}^{Q^2} \sum_{j=0}^E T_{ij}^{noobj} [\bar{C}_i \ln(C_i) + (1 - \bar{C}_i) \ln(1 - \bar{C}_i)] \quad (14)$$

$$L_{cls} = \sum_{i=0}^{Q^2} T_{ij}^{obj} \sum_{c \in k} \{ \bar{p}_i^j(c) \ln p_i^j(c) + [1 - \bar{p}_i^j(c)] \ln [1 - p_i^j(c)] \} \quad (15)$$

式中:  $I(A, B)$  为预测框  $B$  和真实框  $A$  的交并比;  $\rho^2(A_{ctr}, B_{ctr})$  为预测框中心点  $B_{ctr}$  和真实框中心点  $A_{ctr}$  的欧氏距离;  $m$  为同时包含预测框和真实框的

最小封闭区域的对角线距离;  $\alpha$  为权重函数;  $\nu$  为长宽比相似性度量系数;  $w^{gt}, h^{gt}$  分别为真实框的宽和高;  $w, h$  分别为预测框的宽和高;  $Q^2$  为网格数;  $E$  为每个网格中先验框个数;  $T_{ij}^{obj}$  为第  $i$  个网格上产生的第  $j$  个预测框内包含目标;  $T_{ij}^{noobj}$  为第  $i$  个网格上产生的第  $j$  个预测框内不包含目标;  $\bar{C}_i$  为真实置信度;  $C_i$  为预测置信度;  $\lambda_{noobj}$  为自行设定的计算系数;  $k$  为目标分类数;  $\bar{p}_i^j(c)$  为框内目标属于类别  $c$  的真实概率;  $p_i^j(c)$  为框内目标属于类别  $c$  的预测概率。

## 2 实验结果与分析

### 2.1 实验环境及数据选择

实验运行环境为 Ubuntu18.04, CPU 为 2.50 GHz 的 E5-2678, 内存为 62 GB, GPU 为 NVIDIA GeForce RTX 2080 Ti, 利用 Cuda10.0 和 Cudnn7.5.1 的驱动程序支持 GPU 加速, 显存为 11 GB, python 版本为 3.5.6。实验中使用 Keras2.2 和 Tensorflow1.13.1 深度学习框架。

本文以煤矿井下带式输送机上中块煤和大块煤为研究对象, 实验数据集来源于真实煤矿井下作业监控视频片段, 涵盖了不同尺寸大小的煤块。共采集 4 500 张图像, 图像大小为  $227 \times 227$ , 其中测试集

450 张图像,训练集和验证集共 4 050 张图像。

2.2 模型训练

利用 LabelImg 对所选数据集中待检测目标信息进行标注,用于模型训练。参数设置:模型训练时动量系数为 0.9,学习率为 0.001,批尺寸为 16,训练迭代次数为 100。

模型的损失函数曲线如图 5 所示。可看出在迭代过程中,训练集和验证集的损失值呈明显下降趋势,并且在 70 次迭代后收敛过程平稳,说明融合轻量级网络和双重注意力机制的改进 YOLOv4 模型未出现过拟合现象。




图 5 损失函数曲线  
Fig.5 Loss function curve

2.3 检测结果

融合轻量级网络和双重注意力机制的改进 YOLOv4 模型对不同尺寸煤块进行检测的结果如图 6 所示。可看出模型根据不同尺寸的目标识别框可识别尺寸不同的大块煤和中块煤。



图 6 不同尺寸煤块检测结果

Fig.6 Test results of coal blocks of different sizes

在 YOLOv4 模型基础上进行不同改进做对比实验,结果见表 1。可看出 YOLOv4 模型的权重文件大小为 244.9 MB,精确率为 90.58%,召回率为 33.47%,平均精度均值为 64.31,漏检率为 49%;YOLOv4\_M 模型采用 MobileNet 轻量化网络模型替换 YOLOv4 模型的主干网络,相较于 YOLOv4 模型其权重文件减少了 36.6%,表明 YOLOv4\_M 模型更加轻便;YOLOv4\_MA 模型在 YOLOv4\_M 模型基础上嵌入具有双重注意力机制的 CBAM,相较于 YOLOv4 模型,其权重文件减小了 36.46%,

精确率提高了 2.16%,召回率提高了 20.4%,平均精度均值提高了 14.37%,漏检率降低了 16%,表明 YOLOv4\_MA 模型可提高煤块检测精度。

表 1 不同模型性能对比

| Table 1 Performance comparison of different models |               |           |           |              |           |
|----------------------------------------------------|---------------|-----------|-----------|--------------|-----------|
| 模型                                                 | 权重文件<br>大小/MB | 精确<br>率/% | 召回<br>率/% | 平均精度<br>均值/% | 漏检<br>率/% |
| YOLOv4                                             | 244.9         | 90.58     | 33.47     | 64.31        | 49        |
| YOLOv4_M                                           | 155.3         | 92.51     | 53.87     | 71.52        | 42        |
| YOLOv4_MA                                          | 155.6         | 92.74     | 53.87     | 78.68        | 34        |

YOLOv4 模型和 YOLOv4\_MA 模型检测速度对比见表 2。与 YOLOv4 模型相比,YOLOv4\_MA 模型检测速度提升了 19 帧/s,在处理单张图像时耗时减少了 1.31 s,表明 YOLOv4\_MA 模型可有效提高检测速度。

表 2 不同模型检测速度对比

| Table 2 Detection speed comparison of different models |                          |            |
|--------------------------------------------------------|--------------------------|------------|
| 模型                                                     | 帧速率/(帧·s <sup>-1</sup> ) | 处理单张图像耗时/s |
| YOLOv4                                                 | 44                       | 4.57       |
| YOLOv4_MA                                              | 63                       | 3.26       |

YOLOv4 和 YOLOv4\_MA 模型对带式输送机上煤块检测结果如图 7 所示。可看出在煤块分布不均匀的情况下,YOLOv4\_MA 模型可准确检测到距离较近的不同大小煤块,减少了煤块漏检情况。



(a) 原始图像 (b) YOLOv4 (c) YOLOv4\_MA

图 7 不同模型下带式输送机煤块检测结果

Fig.7 Coal block test results of belt conveyor under different models

3 结论

(1) 提出了一种融合轻量级网络和双重注意力机制的改进 YOLOv4 模型。基于 K-means 聚类算法重新聚类先验框,提高了模型检测精度;将 YOLOv4 模型的主干网络替换为 MobileNet 轻量级网络模型,在不损失精度的同时,提高了模型检测速度;嵌入具有通道和空间双重注意力机制的

CBMA,在不影响检测速度的前提下,提高了对不同尺度煤块的感知能力,减少了漏检、误检情况。

(2) 相较于 YOLOv4 模型,改进 YOLOv4 模型权重文件减小了 36.46%,精确率提高了 2.16%,召回率提高了 20.4%,平均精度均值提高了 14.37%,漏检率降低了 16%,检测速度提升了 19 帧/s,处理单张图像耗时减少了 1.31 s,表明改进 YOLOv4 模型可提高煤块检测精度和检测速度。

参考文献(References):

[1] 李占利,陈佳迎,李洪安,等. 胶带输送机智能视频检测与预警方法[J]. 图学学报,2017,38(2): 230-235.  
LI Zhanli, CHEN Jiaying, LI Hong'an, et al. Research on intelligent monitoring and warning method of belt conveyor [J]. Journal of Graphics, 2017, 38 (2): 230-235.

[2] 徐青云,赵耀江,李永明. 我国煤矿事故统计分析及今后预防措施[J]. 煤炭工程,2015,47(3):80-82.  
XU Qingyun, ZHAO Yaojiang, LI Yongming. Statistical analysis and precautions of coal mine accidents in China[J]. Coal Engineering, 2015, 47(3): 80-82.

[3] HU Chuan, CAO Huiping. Aspect-level influence discovery from graphs [J]. IEEE Transactions on Knowledge & Data Engineering, 2016, 28 (7): 1635-1649.

[4] WU Jianxin, YANG Hao. Linear regression-based efficient SVM learning for large-scale classification [J]. IEEE Transactions on Neural Networks & Learning Systems, 2015, 26(10): 2357-2369.

[5] FORSYTH D. Object detection with discriminatively trained part-based models [J]. Computer, 2014, 47(2):6-7.

[6] 贾建英,董安国. 基于联合直方图的运动目标检测算法[J]. 计算机工程与应用, 2016, 52(5):199-203.  
JIA Jianying, DONG Anguo. Moving target detection algorithm based on joint histogram [J]. Computer Engineering and Applications, 2016, 52(5): 199-203.

[7] LE M, WOO B, JO K. A comparison of SIFT and Harris conner features for correspondence points matching[C]//The 17th Korea-Japan Joint Workshop on Frontiers of Computer Vision(FCV), Ulsan, 2017: 1-4.

[8] 吕志强. 复杂环境下煤矿皮带运输异物图像识别研究[D]. 徐州:中国矿业大学,2020.  
LYU Zhiqiang. Research on image recognition of foreign bodies in the process of coal mine belt transportation in complex environment[D]. Xuzhou;

China University of Mining and Technology, 2020.

[9] WANG Yuanbin, WANG Yujing, DANG Langfei. Video detection of foreign objects on the surface of belt conveyor underground coal mine based on improved SSD[J]. Journal of Ambient Intelligence and Humanized Computing, 2020(9):1-10.

[10] 胡璟皓,高妍,张红娟,等. 基于深度学习的带式输送机非煤异物识别方法[J]. 工矿自动化, 2021, 47(6): 57-62.  
HU Jinghao, GAO Yan, ZHANG Hongjuan, et al. Research on the identification method of non-coal foreign object of belt conveyor based on deep learning [J]. Industry and Mine Automation, 2021, 47 (6): 57-62.

[11] 杜京义,陈瑞,郝乐,等. 煤矿带式输送机异物检测[J]. 工矿自动化, 2021, 47(8):77-83.  
DU Jingyi, CHEN Rui, HAO Le, et al. Coal mine belt conveyor foreign object detection [J]. Industry and Mine Automation, 2021, 47(8): 77-83.

[12] 张伟,庄幸涛,王雪力,等. DS-YOLO: 一种部署在无人机终端上的小目标实时检测算法[J]. 南京邮电大学学报(自然科学版), 2021, 41(1):86-98.  
ZHANG Wei, ZHUANG Xingtao, WANG Xueli, et al. DS-YOLO: a real-time small object detection algorithm on UAVs[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2021, 41(1): 86-98.

[13] MITTAL S. A survey on optimized implementation of deep learning models on the NVIDIA Jetson platform[J]. Journal of Systems Architecture, 2019, 97: 428-442.

[14] HOWARD A G, ZHU Menglong, CHEN Bo, et al. MobileNets efficient convolutional neural networks for mobile vision applications[EB/OL]. (2018-01-22) [2021-03-23]. <https://arxiv.org/abs/1704.04861> arXiv:1704.04861. 2017.

[15] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//2018 ECCV Conference on Computer Vision, Berlin, 2018: 3-19.

[16] KANUNGO T, MOUNT D, NETANYAHU N, et al. A local search approximation algorithm for k-means clustering [J]. Computational Geometry, 2004, 28 (23): 89-112.

[17] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, 2020: 1571-1580.