



长期使用的过程中又不可避免的易夹杂大块矸石,锚杆等异物,容易造成皮带划伤、撕裂、落煤口堆煤堵煤甚至断裂,严重影响煤矿安全高效生产和煤炭质量。因此,精准实时的识别输送带上的异物对于确保输送带的正常运行和提高生产效率至关重要。

近些年基于深度学习的卷积神经网络的目标检测算法发展迅速,主要分为以 Faster R-CNN 为代表的两阶段检测算法和以 YOLO 系列为代表的一阶段检测算法,已有众多学者使用深度学习的方法对煤矿井下输送带异物进行检测,吕志强<sup>[3]</sup>针对煤矿井下粉尘大,对比度低的问题,选择以 VGG16 作为特征提取网络以改进 Faster R-CNN,识别皮带运输过程中存在的异物。胡璟皓等<sup>[4]</sup>针对非煤异物识别模型缺乏定位能力的问题,在 YOLOv3 网络中引入 Focal Loss 函数,提高了模型的定位能力。郝帅等<sup>[5]</sup>针对输送带异物识别易受煤尘干扰以及光照不均的影响,在 YOLOv5 中引入卷积块注意力模型(convolutional block attention module,CBAM),提高异物在网络中的特征表达能力。史凌凯等<sup>[6]</sup>针对输送机异物识别在井下低光照高粉尘的环境下适应性差的问题,提出了一种基于改进掩码区域卷积神经网络的刮板输送机铁质异物多目标检测方法,提高了检测精度。Dai 等<sup>[7]</sup>针对煤矿井下复杂环境输送带异物检测精度低的问题提出了一种自适应加权多尺度 Retinex 图像增强算法,以提高采集到的皮带输送线图像质量,并结合帧差法和面积法,设计了一种改进的多尺度模板匹配算法,用于筛选和识别混在煤炭中的大型异物。毛清华等<sup>[8]</sup>针对带式输送机高速运行环境中高效、准确识别异物及模型部署不便等问题,在主干提取网络引入轻量化无参注意力机制和引入深度可分离卷积代替主干特征提取网络中的普通卷积,提高异物识别速度。梅晓虎等<sup>[9]</sup>为了实现对于输送带上的异物快速准确的识别,选用 YOLOv7-tiny 模型,在高效层聚合网络(efficient layer aggregation network,ELAN)模块中添加特征拼接单元并优化检测来提高检测精度。Luo 等<sup>[10]</sup>重点关注于检测速度,对 YOLOv5 的骨干和颈部进行了改进,以实现深度轻量级物体检测网络。洪炎等<sup>[11]</sup>针对不同尺寸异物和小目标异物存在错检、漏检情况,在 YOLOv8 网络中引入高效通道注意力机制,并将检测头改为小目标检测头来增强对小目标的敏感性。

针对以上研究分析,上述研究均在原来模型的基础上进行了改进,取得了不错的效果,但仍然存在漏检误检,模型过大以及对遮挡异物检测精度较低的问题。虽然上述文献[3]研究中以 Faster R-CNN 为代表的两阶段目标检测算法检测精度较高,但检测速度较慢,无法满足煤矿输送带异物检测实时性的要求;YOLO 系列算法因其一阶段目标检测算法的特性,在实时目标检测领域应用广泛,文献[4]采用的 YOLOv3<sup>[12]</sup>模型相对较老,相较于后续版本检测精度较低,文献[5-7]都是针对煤矿井下低光照,高

粉尘的复杂环境对异物识别的干扰,并没有对异物本身被遮挡且异物尺度多变进行研究,会漏检误检被遮挡和异物尺度变化大的异物。文献[8-10]都是重点关注检测速度的问题,文献[8-9]都是对 YOLOv7<sup>[13]</sup>的模型结构进行改进,文献[10]是对 YOLOv5<sup>[14]</sup>的模型进行改进,虽然检测速度提升了,但也都没有关注遮挡问题,在遮挡场景中检测精度较低,并且 YOLOv7 和 YOLOv5 相对于后续出来的 YOLO,版本也相对较低,检测性能不如后来新的 YOLO 版本。后来出现的 YOLOv9<sup>[15]</sup>以及 YOLOv10<sup>[16]</sup>虽然检测精度相对较高,但在训练和推理时需要较多的计算资源,检测速度较慢,煤矿井下输送带异物检测需要实时的高精度检测,而 YOLOv8<sup>[17]</sup>是精度和速度平衡,YOLOv8 在保持高精度的同时,进一步提升了检测速度,适合输送带异物检测实时场景。上述文献[11]就是在 YOLOv8 的基础上进行的改进,并针对异物尺寸和小目标问题进一步提高了检测精度,但添加的改进部分导致模型变大,速度降低,YOLOv8 的精度和速度优势不再平衡,并且该文献重点关注的是小目标问题,也会漏检误检部分遮挡异物,而 YOLOv11 作为最新的 YOLO 版本,它在 YOLOv8 的基础上进一步改进,在保持 YOLOv8 精度的同时,减少了参数量,进一步提高了检测速度,是精度和速度的最佳平衡,更适合输送带异物检测实时场景,但煤矿井下输送带异物被遮挡,尺度多变,都会影响检测精度,导致 YOLOv11 无法充分发挥其本身的优势。

所以针对以上问题,本文在 YOLOv11 模型中引入分离和增强注意力模块(separated and enhancement attention module,SEAM),增强模型对输送带异物未遮挡部分关键特征的关注同时通过其他视角推断出被遮挡部分的特征,提升遮挡异物的检测精度;设计 C3k2\_DCN 模块,改善模型对输送带异物本身以及遮挡后的形状和尺度变化的适应能力,减少尺度多变的异物漏检误检情况;对模型进行优化,替换 Conv 为 GhostConv,改进损失函数完全交并比(complete intersection over union,CIoU)<sup>[18]</sup>为损失函数加权交并比(wise intersection over union)WIoU,减少模型的参数量,提高检测速度,提出了一种改进的煤矿井下输送带异物检测模型 SDGW-YOLOv11。

## 1 SDGW-YOLOv11 异物检测方法

YOLOv11 在保持高检测精度的同时,进一步提高了检测速度,这使得它更适合应用于输送带异物实时监测这类场景。然而,在煤矿井下进行输送带异物检测时,异物容易被煤遮挡或者异物之间相互遮挡,此外,大块矸石和锚杆的形状多变且不规则,加上不同尺度和大小的异物遮挡问题,这些因素均会对 YOLOv11 的检测精度产生影响。YOLOv11 网络结构的主要优点在于 C3K2 模块和跨通道金字塔显著注意力模块(cross stage partial with pyramid squeeze attention,C2PSA)。C3K2 模块借鉴了 YOLOv7

中 ELAN 结构的优势,通过增加更多的分支和跨层连接,增强了模型的梯度流。C2PSA 模块则整合了跨部分通道 (cross stage partia,CSP) 模块结构和金字塔显著注意力 (pyramid saliency attention,PSA)模块,主要目的是提升特征提取能力。尽管这些模块在提升模型性能方面发挥了作用,但它们并未针对遮挡问题和不规则形状及尺度变化进行专门优化。因此,YOLOv11 在处理遮挡和尺度多变的场景时,检测精度会有所下降。鉴于此,本文旨在对 YOLOv11 模型进行改进,以应对异物遮挡和尺度变化问题。

本文改进后的 YOLOv11 模型网络结构如图 1 所示,主要有 3 个改进部分:1)引入 SEAM 注意力改善异物遮挡

检测。在 YOLOv11 网络 Neck 端的 C3K2 模块后面添加 SEAM 注意力机制,降低其受煤或其它异物遮挡的干扰,减少遮挡异物漏检误检情况;2)设计 C3K2-DCN 模块适应异物尺度变化。结合可变形卷积 v3 (deformable convolutional networks v3,DCNv3)的优势,设计为 C3K2\_DCN 模块,并引入主干网络,改善传统的卷积检测容易漏检误检尺寸变化异物的问题;3)替换 GhostConv 和 WIoU 进行模型优化。将 YOLOv11 颈部网络的普通卷积 Conv 替换为轻量化卷积 GhostConv,减少模型的参数量,并采用 WIoU 损失函数替换原有损失函数 CIoU,提高收敛速度和回归精度。

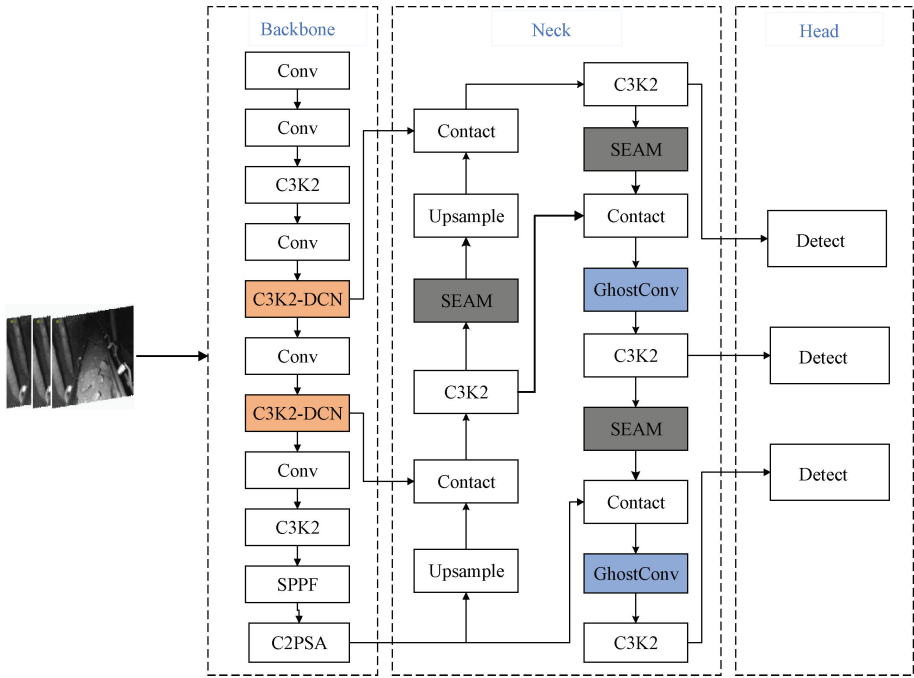


图 1 SDGW-YOLOv11 网络结构  
Fig. 1 SDGW-YOLOv11 network structure

1.1 引入 SEAM 注意力改善异物遮挡检测

在煤矿井下输送带的异物检测任务中,异物容易被煤遮挡,或者异物之间相互遮挡,容易导致 YOLOv11 在检测时发生漏检或误检。YOLOv11 虽然在目标检测上表现优异,但其依赖于单一视角和尺度的特征提取,可能无法有效捕捉到被遮挡较多的异物特征。

SEAM 是一种新的自集成注意力机制,尤其在处理遮挡、多尺度特征融合场景中具有显著优势。结构如图 2 所示,该机制通过多视角特征融合和一致性正则化,可以增强模型对输送带异物未遮挡部分关键特征的关注同时通过其他视角推断出被遮挡部分的特征,有效提升遮挡异物的检测精度,所以本文引入 SEAM 注意力机制。

多个视角指的是从不同的空间位置或观察角度对同一目标进行特征提取的过程。当输送带异物被部分遮挡时,比如一个大块异物被煤部分遮挡中间,YOLOv11 本身

只检测到露出的左右两部分,无法识别被遮挡的区域,如果未遮挡部分和原来形状尺度变化较大就会出现漏检情况。SEAM 通过多视角特征融合,可以从多个位置和尺度上同时提取特征,比如在上述大块异物被煤部分遮挡中间的场景中,就可以从遮挡煤块的两侧获取不同的异物视角信息,进而更全面地理解和识别异物的整体形态,而不仅仅依赖于未遮挡的部分。同时在不同尺度视角方面,当异物被遮挡时,模型可以从较小的尺度上提取到被遮挡的部分的特征,并从较大的尺度上获得该异物整体的大体轮廓。这种多尺度的特征融合,有助于改善对于遮挡物的检测,因为不同尺度下的特征提供了更多维度的信息,从而减少由于遮挡变化而带来的漏检问题。

一致性正则化的核心思想是确保模型在面对不同输入条件时保持一致的输出。在煤矿井下输送带异物检测中,不同的输入条件指的就是同一种异物有的没有被遮



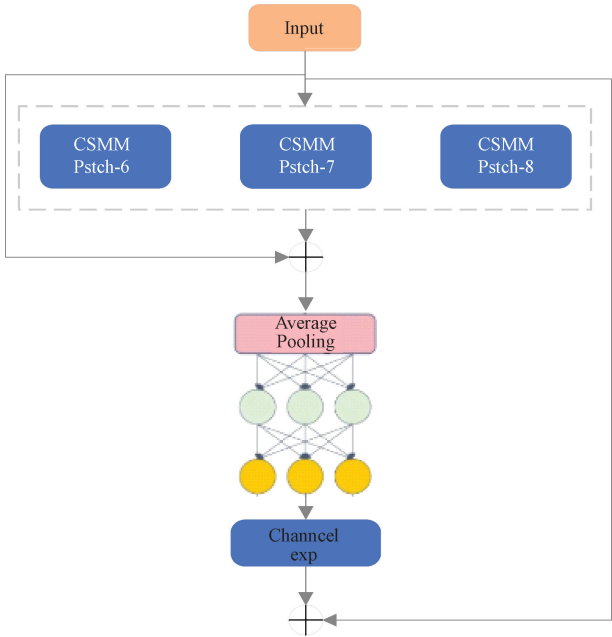


图 2 SEAM 结构  
Fig. 2 SEAM structure

挡,有的异物被遮挡,并且被遮挡的程度也会有不同,比如异物中有的锚杆有的完全没有被遮挡,有的被埋在煤中只漏出部分结构,模型可能只能看到锚杆的一小部分或其轮廓。通过一致性正则化,模型将学会如何从局部的、部分可见的信息中推断出被遮挡的锚杆全貌。即使某些细节(如锚杆的末端)不可见,模型仍然能根据周围的锚杆的形状、大小和位置等信息推测出遮挡部分的形态,对于同一种异物,能够在其不同部分被遮挡或从不同角度观察时,做出相同的检测结果。

1.2 设计 C3K2-DCN 模块适应异物尺度变化

在煤矿输送带上进行异物检测时,大块矸石、锚杆本身形状就多变不规则,加上这些异物容易被煤遮挡或者因视角变化而变形,会有各种形状和大小的大块矸石和锚杆,而 YOLOv11 中使用的传统卷积核是固定形状的,对于形状规则变化不大的目标检测性能较好,在处理异物尺寸形状不一或局部被遮挡的情况下,难以准确地感知到目标的变化,导致漏检或误检的情况。

一种解决思路是扩充数据集,使得数据集包含异物的各种形态,从而提高模型的学习能力,这种解决思路在井上等正常的环境下可以采用,但在煤矿井下这种特殊场景下,输送带处环境极其复杂,输送带位于井下深处狭窄、拥挤的通道中,光照昏暗、存在大量的尘埃以及输送带位置空间非常有限,难以采集包含大块矸石和锚杆的各种形态的大量数据集,人工设计扩充数据集非常复杂,因此这种方法无法适用于煤矿输送带异物检测场景。

所以本文结合 DCNv3 可变形卷积的优势,将其网络结构与 C3K2 模块进行融合,设计 C3K2-DCN 模块,该模

块可以更好地捕捉输送带异物的局部形状和位置变化,改善模型对异物尺度变化的适应能力,从而提高检测精度。可变形卷积结构如图 3 所示,通过引入偏移量<sup>[19]</sup>,使得卷积核能够根据异物的具体形状和位置进行自适应调整,当大块矸石或锚杆的某部分被遮挡时或者其本身尺度变化较大时,传统卷积难以同时适应这些尺度的变化,而可变形卷积可以通过学习到的偏移量来适应不同尺度下的物体特征,并且对于锚杆这样的长条形异物,传统卷积核可能难以精确捕捉到其细长特征,而可变形卷积则能够根据锚杆的局部形状动态调整卷积核,捕捉到更多的细节,从而减少漏检和误检的情况。其计算过程如下:

$$y(p_0) = \sum_{p_n \in R} w(p_n) \cdot x(p_0 + p_n + \Delta p_n) \quad (1)$$

其中,  $w$  为卷积核,  $x$  为输入输送带异物图像特征,  $R$  为  $[(-1,-1),(-1,0),\dots,(0,1),(1,1)]$ ,  $p_n$  是卷积核的每个位置。




图 3 可变形卷积结构  
Fig. 3 Structure of deformable convolution

1.3 替换 GhostConv 和 WIoU 进行模型优化

由于添加了 SEAM 注意力机制,导致模型变大,影响检测速度,因此需要对模型进行优化。首先使用 GhostConv 替换部分 Conv, GhostConv 可以在保持计算效率的同时减少内存占用,减少模型参数量,从而提高模型检测速度,然后采用 WIoU 损失函数替换 CIoU 损失函数,提升收敛速度和回归精度。

GhostConv 将原始的卷积核分解为一个主要卷积核和多个幽灵卷积核,主要卷积核的大小与传统卷积核相同,而幽灵卷积核的大小通常较小<sup>[20]</sup>,在进行卷积操作时,首先使用主要卷积核进行卷积运算,然后再使用幽灵卷积核进行补充卷积运算。这样可以减少卷积核的数量,从而降低内存的占用。因此本文将颈部网络的普通卷积 Conv 替换为轻量化卷积 GhostConv。YOLOv11 在边界框的回归损失计算中采用了 CIoU 方法,但 CIoU 方法存在一些不足之处。首先,CIoU 未考虑困难和容易样本之间的平衡问题;其次,CIoU 在损失函数中使用了长宽比作为一项惩罚

因子,如果真实边界框和预测边界框具有相同的长宽比但不同的实际宽度和高度值时,这一惩罚项不能准确反映两者之间的真实差异,CIoU 公式如下:

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{(c_w^2 + c_h^2)^2} + \frac{4}{\pi^2} (\tan^{-1} \frac{w}{h} - \tan^{-1} \frac{w^{gt}}{h^{gt}})^2 \quad (2)$$

其中,  $w, h$  分别表示预测框的宽和高,  $w_{gt}$  框中心点与预测方框中心点之间的欧氏距离,  $c_w, c_h$  为预测框和真实框的最小外接矩形的宽和高,  $IoU$  表示预测框和真实的框的交并比。

损失函数高效交并比 (efficient intersection over union, EIoU)<sup>[21]</sup> 通过引入指数因子,更好地平衡了损失函数中的不同目标尺度,适用于旋转目标、长宽比变化大的场景,但它的推理速度较慢。损失函数软交并比 (soft intersection over union, SIoU)<sup>[22]</sup> 通过将交集项分子和分母中的平方项引入,增加了对边界框回归误差的敏感性,SIoU 在计算上相对简洁,推理速度较快,但在输送带异物遮挡和形状不规则的复杂场景中会影响检测精度。

这几种主流损失函数采用的是静态聚焦机制,导致不能充分利用其单调潜力,而 WIoU 不仅考虑了目标框和真实框之间的 IoU 值以及它们之间的距离,还引入了动态非单调聚焦机制<sup>[23]</sup>,提高了模型定位对象的能力,WIoU 还通过加权机制,可以更有效地处理多尺度目标,可以提高模型对输送带异物遮挡和多尺度的检测能力,提高收敛速度和回归精度。因此本文选用 WIoU 损失函数代替原来的损失函数。其公式如下:

$$L_{WIoU} = R_{WIoU} \times L_{IoU} \quad (3)$$

$$R_{WIoU} = \exp\left(\frac{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2}{(c_w^2 + c_h^2)}\right) \quad (4)$$

$$L_{IoU} = 1 - IoU \quad (5)$$

其中,  $R_{WIoU}$  表示高质量锚框的损失。

## 2 实验设计与结果分析

### 2.1 实验设备

本文实验平台选择 Ubuntu18.04.6 版本;CPU 型号为 Intel(R) Core(TM) i9-10900X CPU @ 3.70 GHz;GPU 为 RTX3090;显存容量为 24 GB;系统内存为 64 GB;Torch 为 1.11.0,CUDA 为 11.4。

### 2.2 实验数据

实验数据一部分来自煤矿井下输送带工作时的监控视频图像,先进行初步筛选,排除损坏的视频和异常的场景视频,然后对视频数据进行切帧处理,再对数据集进行数据清洗:去除重复数据;排除黑暗以及工人矿灯对照导致难以识别的数据;最后注意隐私保护。另一部分来自中国矿业大学公开的煤矿井下输送带异物数据集,总共图片

8 116 张,对这些数据集预处理后进行标注,分为训练集 5 616 张,测试集 2 500 张。

### 2.3 实现过程

1) 创建环境,连接服务器,进入 base 环境,使用命令 `conda create-n yolov11 python=3.11` 创建新环境 yolov11,使用命令 `conda activate yolov11` 激活新环境 yolov11。

2) 安装依赖和权重,从 GitHub 上拉取代码到本地,使用命令 `pip install` 导入项目所需要的库,虽然上述操作可以自动下载 yolov11 n. pt,但是经常打不开,所以需要手动下载。

3) 导入输送带异物数据集,使用 Label Image 标注输送带异物数据集为 YOLO 格式,再将数据集放到 `ultralytics\datasets` 文件夹下,在 `datasets` 文件夹下自己的数据包中新建一个数据加载配置文件 `mydata.yaml`,写入自己数据集目录以及种类。使用 YOLOv11 官方给定的命令行训练/验证/,注意对应好自己的文件路径。

4) 添加 SEAM 注意力机制,将 SEAM 注意力机制代码添加到 `modules/conv.py` 代码中,然后将该方法名添加到最上方的引用中,同样也需要将该方法名添加到 `modules/_initial_.py` 的同样位置,然后继续修改 `cfg` 包中的 `.yaml` 模型文件,将 SEAM 加到 `head` 中的 `C3K2` 模块后面,由于是添加而不是替换,同时需要调整每个添位置前面的引用,否则无法生效。

5) 引入设计的 C3K2-DCN 模块,将该模块代码添加到 `modules/block.py` 代码中,然后将该方法名添加到最上方的引用中。同理将该方法名添加到 `modules/_initial_.py` 的同样位置,然后更改 `cfg` 包中的 `.yaml` 模型文件,将设计的 C3K2-DCN 替换 `backbone` 中的第 2、3 个 `C3K2` 模块,建议自己重新创建一个,避免混乱,后面运行的时候只需要指定该文件即可。

6) 替换轻量化卷积,更改 `cfg` 包中的 `.yaml` 模型文件,将 `head` 中的 `conv` 替换为 `GhostConv`。

7) 改进损失函数并训练验证,在 `utils/loss.py` 中找到 `BboxLoss` 类,找到对应的 CIoU 损失函数部分,换为 WIoU 损失函数,并将 `iou` 设置为 `WIoU=true`。最后指定好自己的创建的 `.yaml` 模型文件,并指定好自己的 `mydata.yaml`,调用官方运行命令使用自己的改进的模型对自己构建的数据集进行训练和验证。

### 2.4 评价指标

本实验使用精确率 (Precision)、召回率 (Recall)、平均精度均值 (mAP@0.5) 和 FPS 对模型进行评价,精确率指的是模型正确预测为正类别的样本数量与所有被模型预测为正类别的样本数量的比率,计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

召回率指的是模型正确预测为正类别的样本数量与所有真正的正类别样本数量的比率,计算公式为:

$$Recall = \frac{TP}{TP + FN} \tag{7}$$

其中,  $TP$  是指模型正确检测到的正样本数量,  $FP$  是指模型错误地将负类别的样本预测为正类别的数量,  $FN$  是指模型未能正确检测到的正样本数量。

平均精度均值  $mAP@0.5$  是指在目标检测任务中, 当 IoU 阈值设定为 0.5 时, 计算出的所有类别的平均精度, 其计算公式如下:

$$mAP@0.5 = \frac{1}{C} \sum_{k=1}^C AP@0.5_k \tag{8}$$

$$AP@0.5 = \frac{1}{n} \sum_{i=1}^n p_i = \frac{1}{n} p_1 + \frac{1}{n} p_2 + \cdots + \frac{1}{n} p_n \tag{9}$$

其中,  $AP@0.5$  指的是当混淆矩阵的 IoU 的阈值取 0.5 时, 针对这一类样本的平均精确度。

2.5 不同模块消融实验

通过消融实验验证添加 SEAM 模块, 引入设计的 C3K2-DCN 模块, 替换 ChostConv 和 WIoU 损失函数对模型的增益, 在统一的配置以及相同的数据集上的实验结果如表 1 所示。

表 1 不同模块消融实验结果  
Table 1 Results of ablation experiments with different modules

SEAM	C3K2-DCN	GhostConv	WIoU	P/%	R/%	mAP@0.5/%	FPS
				81.5	74.7	84.2	90
✓				84.7	73.9	85.1	80
	✓			84.4	73.7	84.7	83
✓	✓			85.5	73.5	85.0	73
✓	✓		✓	86.2	74.5	85.3	75
✓	✓	✓	✓	86.1	74.1	84.9	82

表 1 中第 1 行为原始 YOLOv11 网络的检测结果, 通过表 1 可以看出, 加入 SEAM 后, 其检测精度相对于原网络提高了 3.2%,  $mAP@0.5$  提升了 0.9%, 改善了由于输送带异物被煤遮挡导致漏检误检的情况; 加入 C3K2-DCN 模块后, 在基本维持 IoU 阈值为 0.5 时的平均精度的基础上, 其检测精度相对于原网络提高了 2.9%, 减小了异物形状尺度多变对检测精度的影响, 提高了模型的抗干扰能力; 当同时加入 SEAM 和 C3K2-DCN 模块时, 其检测精度相对于只加其中一个模块的网络分别提高了 0.8% 和 1.1%; 当损失函数改为 WIoU 损失函数后, 其检测精度相对于未加之前提高了 0.7%,  $mAP@0.5$  提高了 0.3%, 检测速度提高了 2 fps; 当用 GhostConv 替换普通 Conv 后, 在基本维持检测精度的同时, 检测速度提高了 7 fps, 减少了模型的参数量, 提高了检测速度。本文综合各模块的优点, 改进的模型与原网络相比, 检测精度提高了 4.6%,  $mAP@0.5$  提高了 0.7%, 改进的 YOLOv11 模型检测精度可达 86.1%, FPS 可达 82, 这表明改进的模型能更好的适应输送带异物遮挡且尺度多变的场景, 改进的模型检测精度明显提升。

2.6 注意力机制横向对比实验

为了进一步验证 SEAM 注意力机制在处理输送带异物遮挡、多尺度特征融合场景中具有的显著优势, 将其它主流的注意力机制 CBAM<sup>[24]</sup>, 全局注意力机制(global attention mechanism, GAM)<sup>[25]</sup>, 高效通道注意力(efficient channel attention, ECA)<sup>[26]</sup> 分别加入到 YOLOv11 中在相同的条件下进行横向对比, 实验结果如表 2 所示, 可视化

检测对比图如图 4 所示。

表 2 不同注意力机制实验结果对比  
Table 2 Comparison of experimental results of different attention mechanisms

注意力机制	P	R	mAP@0.5
YOLOv11-CBAM	82.6	73.6	84.4
YOLOv11-GAM	83.1	73.3	84.6
YOLOv11-ECA	81.9	72.9	83.6
YOLOv11-SEAM	84.7	73.9	85.1

由表 2 可知, 在 YOLOv11 中引入 SEAM 后检测精度, 召回率以及  $mAP@0.5$  均高于引入其它注意力机制, 表明 SEAM 在煤矿井下输送带异物遮挡场景中的性能优于其它注意力机制, 由图 4 的可视化检测对比图也可以看出, 引入其它注意机制会漏检部分遮挡和尺度变化的异物, 而引入 SEAM 后对遮挡和尺度变化的异物也有良好的检测。

2.7 损失函数横向对比实验

为了验证 WIoU 损失函数动态非单调聚焦机制和加权机制在处理异物遮挡、多尺度复杂实时场景的适配性, 将其与上述提到的其它主流的损失函数 CIoU、EIoU、SIoU 分别加入到 YOLOv11 中在相同的条件下进行横向对比, 实验结果如表 3 所示。

由表 3 可知, 在 YOLOv11 中替换 EIoU 损失函数后, 检测精度有所提高的同时, 检测速度略有下降, 替换为 SIoU 损失函数时, 检测速度提升了但检测精度有所下降,






图4 注意力可视化检测对比

Fig. 4 Attention visualisation detection comparison

而替换为 WIoU 损失函数后平衡了精度和速度,速度和精度都略有提升,更加适合输送带这种遮挡和多尺度复杂的实时检测场景。

表3 不同损失函数实验结果对比

Table 3 Comparison of experimental results with different loss functions

损失函数	P/%	mAP@0.5/%	FPS
YOLOv11-CIoU	81.5	84.2	90
YOLOv11-EIoU	82.0	84.6	88
YOLOv11-SIoU	80.9	83.6	93
YOLOv11-WIoU	82.1	84.5	92

2.8 不同模型对比实验

为验证本文改进的 YOLOv11 模型性能优势,将本文模型与上述提到的目标检测模型 Faster R-CNN、SSD、YOLOv3、YOLOv5、YOLOv7、YOLOv8、YOLOv9、YOLOv10 以及 YOLOv11 在相同的条件下(统一的配置以及相同的数据集)进行实验对比,并对实验结果进行一个可视化展示,表 4 为上述检测模型的结果对比。图 5 为改进的模型和表中前 6 种模型的对比可视化精度图,图 6 为改进的模型和表中后 3 种模型的对比可视化精度图,模型曲线从上到下分别对应图中右下角顺序从上往下。

由表 4 以及图 5 和图 6 可知,SSD 和 YOLOv3 检测精度较低,虽然 Faster R-CNN 检测精度较高,但检测速度较慢,无法满足煤矿输送带异物检测实时性的要求,本文改进的 YOLOv11 模型在精确率和 mAP@0.5 以及 FPS 指标上均高于 YOLOv5、YOLOv7、YOLOv8、YOLOv9、

YOLOv10,相较于 YOLOv11,虽然 FPS 略有下降,但遮挡场景中检测精度明显高于 YOLOv11,提高了 4.6%。

表4 不同模型实验结果对比

Table 4 Comparison of experimental results with the different models

模型	P/%	mAP@0.5/%	FPS
Faster R-CNN	82.1	82.9	19
SSD	73.6	75.3	42
YOLOv3	78.7	77.6	27
YOLOv5	83.6	84.6	56
YOLOv7	80.1	82.2	66
YOLOv8	81.3	84.4	75
YOLOv9	81.6	83.6	45
YOLOv10	82.5	83.9	55
YOLOv11	81.5	84.2	90
本文	86.1	84.9	82

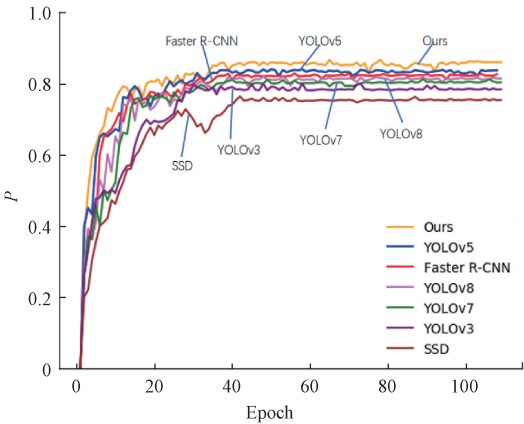


图5 改进模型与前6中模型的可视化精度图

Fig. 5 Plot of visualisation accuracy of the improved model versus the model in the previous 6




图6 改进模型与后3种模型的可视化精度图

Fig. 6 Plot of visualisation accuracy of the improved model against the latter three models

为了进一步验证本文改进的 YOLOv11 模型的性能优势,将本文模型与近期研究者提出的改进的输送带异物检测模型包括文献[5]改进提出的 CBAM-YOLOv5 模型、文献[9]改进提出的 Stair-YOLOv7-tiny 模型以及文献[11]中改进的 YOLOv8 模型在相同的条件下(统一的配置以及相同的数据集)进行实验对比结果如表 5 所示,可视化精度图如图 7 所示,模型曲线从上到下分别对应图中右下角顺序从上往下。

表 5 改进模型实验结果对比

Table 5 Comparison of experimental results with the improved model

模型	P/%	mAP@0.5/%	FPS
文献[5]	84.2	85.1	49
文献[9]	84.4	83.7	85
文献[11]	85.0	85.2	70
本文	86.1	84.9	82

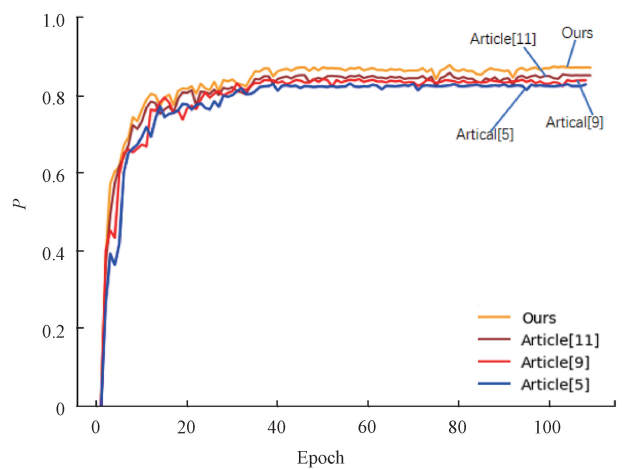


图 7 与改进的模型实验结果可视化精度图

Fig. 7 Visualization of accuracy graphs from experimental results with the improved model

由表 5 以及图 7 可知,相对于文献[5],虽然 mAP@0.5 下降了 0.2%,但检测精度提高了 1.9%,检测速度明显高于文献[5],相较于文献[9],虽然 FPS 略有下降,但对于输送带异物遮挡以及异物尺度多变的场景检测精度高于文献[9],提高了 1.7%,mAP@0.5 提高了 1.2%,相对于文献[11],虽然 mAP@0.5 下降了 0.3%,但在遮挡场景中,精度提高了 1.1%,检测速度提高了 12 fps。综上所述,改进的模型在基本维持检测速度的同时,对于输送带异物遮挡以及尺度多变的场景下,异物漏检误检较少。

3 结 论

针对煤矿井下输送带中的大块矸石和锚杆等异物被遮挡且异物尺度多变容易导致漏检误检问题。本文研究

设计了一种煤矿井下输送带异物检测模型 SDGW-YOLOv11,在 YOLOv11 颈部网络中加入 SEAM 注意力机制,可以减少煤矿井下输送带异物遮挡的干扰,提高了模型对输送带上大块矸石和锚杆的关键特征表达能力,并通过其他视角推断出被遮挡部分的特征,提高了检测精度;通过设计 C3K2-DCN 模块,更好的适应了输送带异物自身以及被遮挡后的尺度的变换性并有效进一步提高对异物的检测精度;通过优化模型,使用 GhostConv 替换部分普通卷积,减少了模型的参数量,提高了检测速度,使用 WIoU 损失函数替换 YOLOv8 原有损失函数,提高了收敛速度和回归精度。

实验结果表明改进的模型能更好的适应输送带异物遮挡场景,可以减少异物尺度变换对异物检测精度的影响,在精确率和 mAP@0.5 指标上均优于 Faster R-CNN、SSD、YOLOv3、YOLOv5、YOLOv7、YOLOv8、YOLOv9、YOLOv10、YOLOv11,SDGW-YOLOv11 模型在输送带异物数据集上检测精度可达 86.1%,相对于原来模型提高了 4.6%。减少了遮挡以及尺度变换异物的漏检误检情况,检测速度可达 82 fps,可充分满足输送带异物实时检测要求。

参考文献

[1] WANG G, REN H, ZHAO G, et al. Research and practice of intelligent coal mine technology systems in China[J]. International Journal of Coal Science & Technology, 2022, 9(1): 24.

[2] 王海军, 王洪磊. 带式输送机智能化关键技术现状与展望[J]. 煤炭科学技术, 2022, 50(12): 225-239.

WANG H J, WANG H L. Status and prospect of intelligent key technologies of belt conveyor[J]. Coal Science and Technology, 2022, 50(12): 225-239.

[3] 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: 1-60.

LYU ZH Q. Research on foreign body image recognition of coal mine belt transport under complex environment[D]. Xuzhou: China University of Mining and Technology, 2020: 1-60.

[4] 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, 90.

HU J H, GAO Y, ZHANG H J, 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, 90.

[5] 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. Foreign object detection in coal mine conveyor belt based on CBAM-YOLOv5[J]. Journal of China Coal Society, 2022, 47(11): 4147-4156.

[6] 史凌凯, 耿毅德, 王宏伟, 等. 基于改进 Mask R-



- CNN 的刮板输送机铁质异物多目标检测[J]. 工矿自动化, 2022, 48(10): 55-61.
- SHI L K, GENG Y D, WANG H W, et al. Multi-object detection of iron foreign bodies in scraper conveyor based on improved Mask R-CNN [J]. Industry and Mine Automation, 2022, 48(10):55-61.
- [7] DAI L L, ZHANG X, GARDONI P, et al. A new machine vision detection method for identifying and screening out various large foreign objects on coal belt conveyor lines[J]. Complex & Intelligent Systems, 2023, 9(5): 5221-5234.
- [8] 毛清华, 李世坤, 胡鑫, 等. 基于改进 YOLOv7 的煤矿带式输送机异物识别[J]. 工矿自动化, 2022, 48(12): 26-32.
- MAO Q H, LI SH K, HU X, et al. Foreign object recognition of belt conveyor in coal mine based on improved YOLOv7 [J]. Industry and Mine Automation, 2022, 48(12): 26-32.
- [9] 梅晓虎, 吕小强, 雷萌. 基于 Stair-YOLOv7-tiny 的煤矿井下输送带异物检测[J]. 工矿自动化, 2024, 50(8): 99-104,111.
- MEI X H, LYU X Q, LEI M. Foreign object detection of coal mine underground conveyor belt based on Stair-YOLOv7-tiny[J]. Industry and Mine Automation, 2024, 50(8): 99-104,111.
- [10] LUO B X, KOU Z M, HAN C, et al. A faster and lighter detection method for foreign objects in coal mine belt conveyors[J]. Sensors, 2023, 23(14): 6276.
- [11] 洪炎, 汪磊, 苏静明, 等. 基于改进 YOLOv8 的煤矿输送带异物检测[J]. 工矿自动化, 2024, 50(6): 61-69.
- HONG Y, WANG L, SU J M, et al. Foreign object detection of coal mine conveyor belt based on improved YOLOv8[J]. Industry and Mine Automation, 2024, 50(6): 61-69.
- [12] DENG L, LI H, LIU H, et al. A lightweight YOLOv3 algorithm used for safety helmet detection[J]. Scientific Reports, 2022, 12(1): 10981.
- [13] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [14] ZHOU F, ZHAO H, NIE Z. Safety helmet detection based on YOLOv5 [C]. 2021 IEEE International Conference on Power Electronics, Computer Applications(ICPECA), 2021: 6-11.
- [15] AN R, ZHANG X, SUN M, et al. GC-YOLOv9: Innovative smart city traffic monitoring solution[J]. Alexandria Engineering Journal, 2024, 106: 277-287.
- [16] LIU W, WANG S, GAO X, et al. A tomato recognition and rapid sorting system based on improved YOLOv10[J]. Machines, 2024, 12(10):689.
- [17] SHEN L, LANG B, SONG Z. Infrared object detection method based on DBD-YOLOv8[J]. IEEE Access, 2023, 11: 145853-145868.
- [18] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. AAAI Conference on Artificial Intelligence, 2020: 12993-13000.
- [19] ZHU X, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308-9316.
- [20] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [21] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [22] GEVORGYAN Z. SiOU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740, 2022.
- [23] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.
- [24] 赵世伟, 段宇光, 曹希博, 等. 基于 AFE-YOLOv7 模型的航空保险丝绕向识别方法[J]. 电子测量技术, 2024, 47(22): 31-38.
- ZHAO SH W, DUAN Y G, CAO X B, et al. Aviation lock-wire twisting direction identification method based on AFE-YOLOv7 model[J]. Electronic Measurement Technology, 2024, 47(22): 31-38.
- [25] LIU Y, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. ArXiv preprint arXiv: 2112.05561, 2021.
- [26] 李苗苗, 华才健, 谢涛, 等. 融合多尺度特征及注意力机制的食品图像识别[J]. 电子测量技术, 2024, 47(18): 164-171.
- LI M M, HUA C J, XIE T, et al. Integrating multi-scale features and attention mechanisms for food imagery cognition [J]. Electronic Measurement Technology, 2024, 47(18): 164-171.

## 作者简介

于绍凯(通信作者), 硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: yy52919@163.com

董立红, 博士, 教授, 主要研究方向为智慧矿山建设顶层设计及大数据、工业互联网等新技术在煤矿领域的应用。

E-mail: 1430315357@qq.com

秦映, 博士, 讲师, 主要研究方向为计算机视觉、信息处理。

E-mail: qiny@xust.edu.cn