

# 基于改进 YOLOv8 的复杂场景下安全帽 佩戴检测算法<sup>\*</sup>

杨瑞君<sup>1</sup> 李悦东<sup>1</sup> 叶 璟<sup>2</sup>

(1. 上海应用技术大学计算机科学与信息工程学院 上海 201418; 2. 上海应用技术大学化学与环境工程学院 上海 201418)

**摘要:** 为解决复杂施工场景中安全帽佩戴检测因人员密集、遮挡和目标体积小,导致模型出现漏检和误检的问题,本文提出一种基于改进的 YOLOv8 的安全帽佩戴检测算法。首先,引入基于大核深度可分离卷积的 CMUNeXtBlock 模块,通过将深度可分离卷积和反向瓶颈技术相结合,提高网络的全局感知能力;其次,设计 C2FICB 模块替换主干网络中的 C2f,融合不同通道和空间位置之间的语义特征,强化网络对多尺度的泛化性,并在颈部网络设计 P2 微尺度目标检测层,提高网络捕捉局部特征的能力;最后,提出一种基于感受野注意力卷积的 RFAConv head(RFAHead)检测头,优化空间特征的表达,进一步强化模型对全局特征的提取能力。实验结果表明在数据集 Safety helmet 上,改进后的模型比基线模型 mAP@0.5 的值提升了 5.2%,mAP@0.5-0.95 的值提升了 3.9%,有效提高安全帽佩戴检测模型的精度。

**关键词:** 目标检测; YOLOv8; 复杂场景; 注意力机制; 安全帽

中图分类号: TP391.4; TN919.8 文献标识码: A 国家标准学科分类代码: 520.6040

## Helmet detection algorithm in complex scenarios based on improved YOLOv8

Yang Ruijun<sup>1</sup> Li Yuedong<sup>1</sup> Ye Jing<sup>2</sup>

(1. School of Computer Science and Information Engineering, Shanghai Institute of Technology, Shanghai 201418, China;

2. School of Ecological Technology and Engineering, Shanghai Institute of Technology, Shanghai 201418, China)

**Abstract:** In order to solve the problem of missing detection and false detection in the helmet wearing detection model in complex construction scenes due to dense personnel, occlusion and small target size, this paper proposes an improved YOLOv8 based helmet wearing detection algorithm. Firstly, the CMUNeXtBlock module based on large core depth-separable convolution is introduced to improve the global awareness of the network by combining depth-separable convolution with reverse bottleneck technology. Secondly, the C2FICB module is designed to replace the C2f in the backbone network and integrate the semantic features between different channels and spatial locations to strengthen the network's multi-scale generalization. Moreover, P2 micro-scale target detection layer is designed in the neck network to improve the network's ability to capture local features. Finally, a RFAConv head(RFAHead) detection head based on the convolution of receptive field attention is proposed to optimize the expression of spatial features and further strengthen the ability of the model to extract global features. Experimental results show that in the Safety helmet dataset, the value of the improved model is increased by 5.2% and that of mAP@0.5-0.95 by 3.9% compared with the baseline model, respectively, effectively improving the accuracy of the safety helmet wearing detection model.

**Keywords:** object detection; YOLOv8; complex scenarios; attention mechanism; safety helmet

## 0 引言

随着工业化进程的推进,建筑和制造等高危行业的安全管理愈发重要,佩戴安全帽的必要性是一个至关重要的

问题,尤其是在高风险的工作环境中。安全帽的使用对于保护工人安全至关重要<sup>[1]</sup>,但据美国国家安全委员会报告称,建筑工地发生超过 65 000 起因未带安全帽导致的头部受伤事件和 1 020 起死亡事件。据《美国工业医学杂志》报

道,共有 2 210 名建筑工人因未正确佩戴安全帽导致创伤性脑损伤而死亡<sup>[2]</sup>。因此对工人正确佩戴安全帽的有效监督和管理至关重要。而在传统的安全帽佩戴监测中,主要依赖于人工监管,这种方法不仅效率低下,而且耗费大量时间和人力资源。相较之下,基于深度学习的安全帽检测技术在提高效率方面具有显著优势,但在复杂的施工环境中,却因遮挡、目标密集以及小体积,导致误检和漏检现象频繁出现。因此在复杂工作环境中实现高效、精准的安全帽佩戴检测具有现实意义。

随着科技的进步,深度学习给图像识别和目标检测领域带来了革命性变化。近年来,基于深度学习的自动化检测方法逐渐成为研究热点,基于深度学习的目标检测方法分为两种主要类别:单阶段检测和双阶段检测。双阶段检测首先从图像中提取候选区域,然后对这些区域进行分类和定位,如区域卷积神经网络(region-based convolutional neural network, R-CNN)<sup>[3]</sup> 算法。在工业实际应用中,双阶段检测模型虽能够提供较高精度,但由于其结构较为复杂,常导致较低的检测速度,难以满足实时性要求。相比之下,单阶段检测模型采用边界框回归,在单个网络中结合了图像分类和预测,显著提高了检测效率,如单次多边框检测(single shot multibox detector, SSD)算法<sup>[4]</sup>,虽在速度上有较大优势,但在精度方面表现不如双阶段模型。而 YOLO<sup>[5]</sup>(you only look once)系列目标检测算法作为单阶段检测模型,有着较好的高效性和准确性,为安全帽佩戴检测提供了新的解决方案。赵红成等<sup>[6]</sup>在 YOLOv3 模型的基础上,采用 GIoU(generalized intersection over union)损失函数,引入金字塔多池化结构,融入注意力机制,使得模型在多尺度检测能力上得到一定提升,但面对被遮挡的情况时模型仍然存在漏检的情况。Yang 等<sup>[7]</sup>提出一种基于 YOLOv4 的安全帽检测网络,利用不同大小卷积核的多尺度通道混合器模块和注意力机制,引导网络关注特定目标的通道特征,提升遮挡检测效果,但该网络在低光照环境下对特征信息的提取能力较为有限。杨永波等<sup>[8]</sup>实现了一种基于改进 YOLOv5s 的安全帽检测算法 YOLO-M3,将 YOLOv5s 的初始网络替换为了 MobileNetV3,进行了轻量化改进,但模型对于目标遮挡情况仍然存在误检漏检的问题。王新良等<sup>[9]</sup>基于 YOLOX 构建软空间金字塔池化,优化特征融合方式,改善了低光照度爆破场景中安全帽的漏检情况,但尚未解决密集遮挡情况下检测精度低的问题。李凤英等<sup>[10]</sup>基于 YOLOv7,采用数据增强的方式来克服复杂环境影响,设计针对性的锚框尺寸进行检测,引入 DeepSort 算法实现安全帽追踪识别,但该方法未考虑目标尺寸较小时对检测精度的影响。王迎龙等<sup>[11]</sup>在 YOLOv8 的基础上对高分辨率特征层添加检测头,引入 BiFormer 注意力机制和 NWD (normalized gaussian wasserstein distance)损失函数,替换 GhostNetV2 模块提升对小目标

的检测能力同时减少模型的参数量和计算量,但并未考虑复杂场景下物体密集遮挡对检测精度的影响。Zhang 等<sup>[12]</sup>在 YOLOv11 的基础上用广义稀疏卷积(generalized-sparse convolution, GSConv)取代传统卷积,设计 C3K2\_FE 模块增强特征提取能力的同时加快检测速度,引入加权双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)机制优化多尺度特征融合的效率,但在复杂环境中对低光照场景数据的适应性较弱。

上述研究在一定程度上提升了安全帽检测的准确度,但由于施工场景下安全帽目标较小、人员密集以及遮挡等因素,现有算法对复杂工地环境的泛化能力不佳,在低光照或高粉尘环境下小目标以及多人员物体间的密集遮挡对检测精度的影响仍未得到妥善解决,仍然存在检测精确率低、误检漏检等问题。针对上述问题,本文提出一种以 YOLOv8 为基线模型改进的复杂环境下安全帽佩戴检测算法,引入 CMUNeXtBlock 模块取代原始主干网络中的卷积,提高网络的全局感知能力;设计 C2FICB 模块替换主干网络中的 C2f,强化网络对多尺度的泛化性;提出 P2 微尺度目标检测层,提高网络捕捉局部特征的能力;最后,设计基于感受野注意力卷积的检测头(receptive-field attention head, RFAHead),进一步强化模型对全局特征的提取能力。

## 1 YOLOv8 模型介绍

YOLO 系列算法是目前目标检测算法中发展最快、使用效果最好的算法之一<sup>[13]</sup>。YOLOv8 的结构在继承 YOLOv5<sup>[14]</sup> 和 YOLOv4<sup>[15]</sup> 优势的基础上进行了优化,其架构主要包含 3 个部分:Backbone、Neck、Head。其中 Backbone 用于提取丰富的图像特征。Neck 部分用于获取不同尺度下的目标信息<sup>[16]</sup>。Head 采用解耦头结构来预测类别信息和位置信息<sup>[17]</sup>。YOLOv8 模型结构如图 1 所示。

## 2 YOLOv8 算法改进

针对现有模型在小目标、密集目标、遮挡目标和背景干扰复杂环境下的误检、漏检的问题,提出一种改进 YOLOv8 安全帽佩戴检测算法。本文模型的工作原理是首先,在主干网络中引入 CMUNeXtBlock 模块,对输入的特征图利用深度可分离卷积提取细节特征,通过反向瓶颈增强全局信息,增强对多尺度目标的灵活感知;同时,提出 C2FICB 模块以增强特征交互,提升不同通道和空间位置之间的信息融合能力,再经过 P2 微尺度目标检测层进一步提取出丰富的小目标特征信息,最后, RFAHead 检测头根据输入特征图动态调整卷积核的感受范围,对特征图进行加权处理,优化空间特征的表达,增强对小物体和复杂场景的检测能力。改进的 YOLOv8 模型结构如图 2 所示。

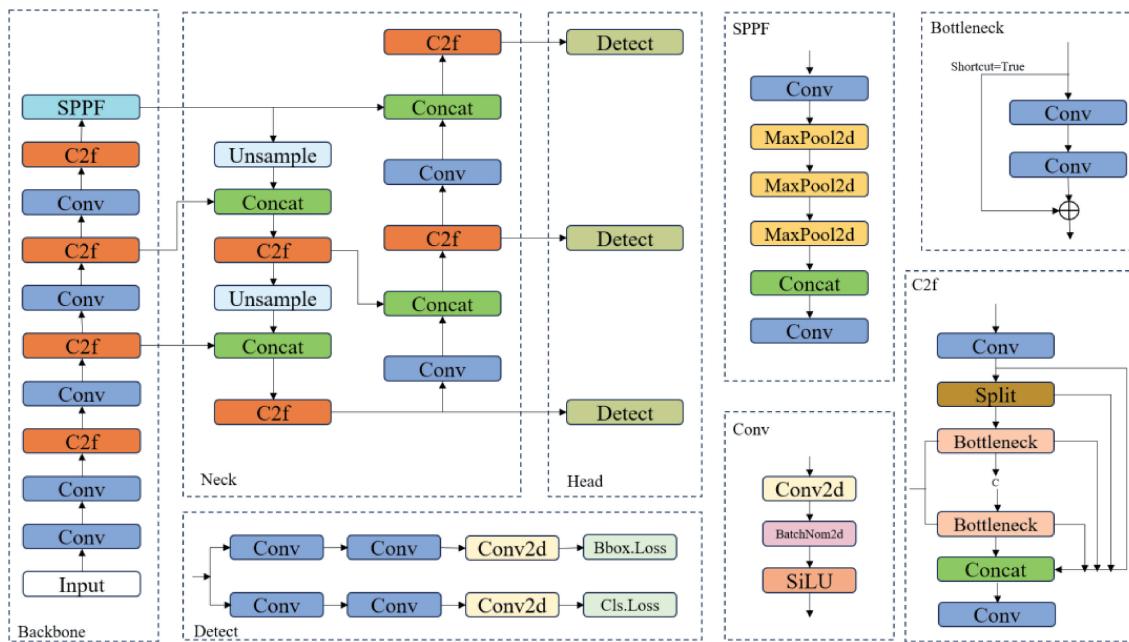


图 1 YOLOv8 网络结构  
Fig. 1 YOLOv8 network architecture

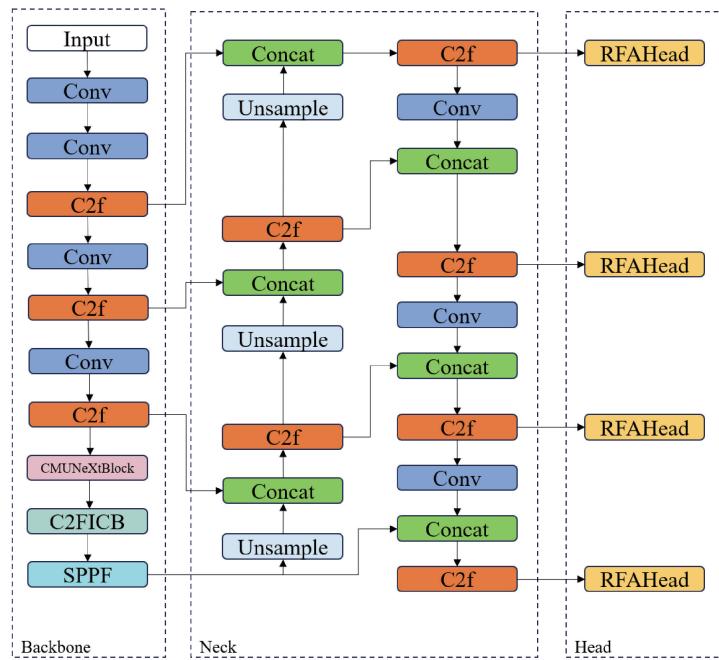


图 2 改进 YOLOv8 模型结构  
Fig. 2 Improved YOLOv8 model architecture

## 2.1 CMUNeXtBlock 模块

YOLOv8 中常规的卷积层使用固定大小的卷积核进行操作,这意味着感受野的范围在整个网络中是固定的,无法根据输入数据的特点进行自适应调整,无法有效捕捉到某些小物体的特征。

因此本文引入 CMUNeXtBlock 模块,其核心组件是深

度可分离卷积,深度可分离卷积通过结合深度卷积和逐点卷积来替代传统的完整卷积操作。其中深度卷积用于提取空间维度的信息,逐点卷积则实现了空间和通道混合的分离。与传统卷积相比,深度卷积有效减少网络的参数量和计算开销。为了充分混合空间和通道的信息,在深度卷积后应用了两个逐点卷积,并进行反向瓶颈设计。反向瓶

颈设计的关键是将两个逐点卷积层之间的隐藏维度设置为输入维度的 4 倍。扩展的隐藏维度能够充分的混合深度卷积提取的全局空间维度信息。此外,在每个卷积层后,使用 GELU 激活函数和后激活的批归一化层。CMUNeXtBlock 的定义如下:

$$f'_l = \text{BN}(\sigma_1\{\text{DepthwiseConv}(f_{l-1})\}) + f_{l-1} \quad (1)$$

$$f''_l = \text{BN}(\sigma_1\{\text{PointwiseConv}(f'_l)\}) \quad (2)$$

$$f_l = \text{BN}(\sigma_1\{\text{PointwiseConv}(f''_l)\}) \quad (3)$$

其中,  $f_l$  表示 ConvMixer 块中第  $l$  层的输出特征图,  $\sigma_1$  表示 GELU 激活函数, BN 表示批归一化层。CMUNeXtBlock 结构如图 3 所示。

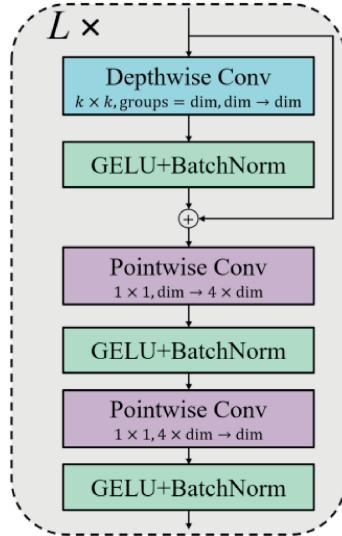


图 3 CMUNeXtBlock 模块

Fig. 3 CMUNeXtBlock

## 2.2 C2FICB 模块

原始 YOLOv8 主干网络中的 C2f 模块作为一种局部连接方法,其多尺度特征提取能力有限,特别是在处理长距离依赖时表现较弱。C2f 模块在特征融合上缺乏灵活性,尤其在处理小目标、目标密集、目标遮挡及复杂场景时,同时由于小物体的特征较为细粒度,无法通过简单的跨层连接和特征融合得到增强。

因此本文设计 C2FICB 模块用于替换主干网络中的 C2f 以增强网络的特征交互与融合能力,提高网络的多尺度特征处理能力。C2FICB 的设计包括将交互式卷积(interactive convolution block, ICB)引入 C2f,利用具有不同内核大小的并行卷积来捕获局部特征和更长范围的依赖关系。第 1 个卷积层旨在使用较小的内核捕获数据中的细粒度、局部模式,第 2 层旨在识别具有更大内核的更广泛、更长范围的依赖关系。ICB 工作流程如下:

$$\mathbf{A}_1 = \phi(\text{Conv1}(\mathbf{S}')) \odot \text{Conv2}(\mathbf{S}') \quad (4)$$

$$\mathbf{A}_2 = \phi(\text{Conv2}(\mathbf{S}')) \odot \text{Conv1}(\mathbf{S}') \quad (5)$$

$$\mathbf{O}_{\text{ICB}} = \text{Conv3}(\mathbf{A}_1 + \mathbf{A}_2) \quad (6)$$

其中,  $\text{Conv1}(\cdot)$  和  $\text{Conv2}(\cdot)$  是两个一维卷积层,  $\phi$

是 GELU 激活函数,然后添加激活的特征并通过最终的卷积层  $\text{Conv3}(\cdot)$ ,  $\mathbf{O}_{\text{ICB}}$  为最终的预测输出。ICB 结构如图 4 所示,C2FICB 结构如图 5 所示。

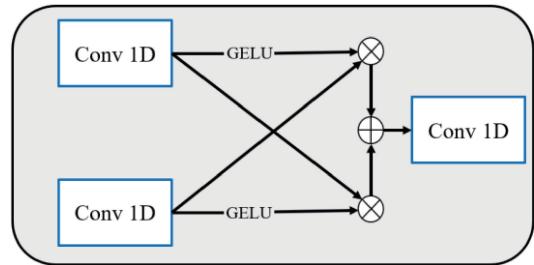


图 4 ICB 结构

Fig. 4 ICB architecture

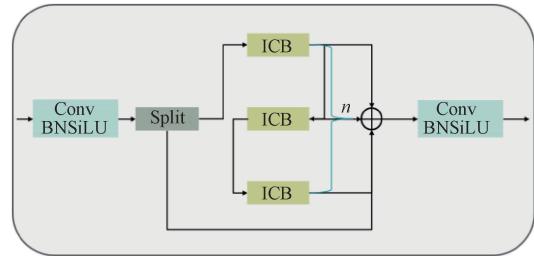


图 5 C2FICB 结构

Fig. 5 C2FICB architecture

## 2.3 P2 微尺度目标检测层

原始 YOLOv8 模型中的 3 个检测头接收来自主干网络及特征金字塔网络融合后的特征图,这些特征图的尺寸分别为 80 pixel × 80 pixel、40 pixel × 40 pixel 和 20 pixel × 20 pixel,分别对应输入图像 640 pixel × 640 pixel 经 8 倍、16 倍及 32 倍下采样后的结果。在主干网络的前向传播过程中,输入图像经过多层卷积操作后,第 2 层的特征图通过 4 倍下采样获得,包含了更多的小目标和细节信息。然而,随着进一步下采样,多个像素点被压缩为单个像素,这一过程中容易丢失小目标和细节区域的关键信息,导致检测精度降低。

为避免这种信息丢失,本文提出 P2 微尺度目标检测层,将第二层的特征图与经过下采样的 3 个特征图进行融合,从而结合低层的细节特征和高层的语义信息,最终生成一个 160 pixel × 160 pixel 的特征图。该特征图作为微尺度目标检测头的输入,具有较小的感受野和更强的特征表达能力,能够更有效地捕捉像安全帽等小尺寸目标的信息,从而显著提升检测精度,如图 6 所示。

## 2.4 RFAHead 检测头

传统的卷积神经网络通过采用共享参数的卷积操作,它并未充分考虑目标在不同位置的形状、大小以及位置信息的差异,因此其性能存在一定的局限性。而将空间注意力机制<sup>[18]</sup>与卷积操作相结合的感受野注意力卷积(receptive-field attention convolution, RFAConv)<sup>[19]</sup>提出

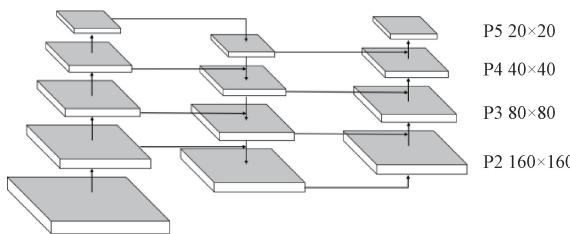


图 6 新增检测层模型结构

Fig. 6 New detection layer model architecture

了一种 RFA 机制,这种机制允许网络为每个感受野生成特定的权重,这样卷积核就可以根据每个感受野内的不同特征动态调整参数,从而解决卷积核参数共享的问题,如

图 7 所示,RFA 的计算公式如式(7)所示。

$$F = \text{Softmax}(g^{1 \times 1}(\text{AvgPool}(X))) * \text{ReLU}(\text{Norm}(g^{k \times k}(X))) = A_{rf} * F_{rf} \quad (7)$$

其中,  $g^{i \times i}$  表示大小为  $i \times i$  的分组卷积,  $k$  表示卷积核的大小,  $\text{Norm}$  表示归一化,  $X$  表示输入的特征图,将注意图  $A_{rf}$  与变换后的感受野空间特征  $F_{rf}$  相乘得到  $F$ 。

本文设计了一种利用 RFAConv 优化的检测头 RFAHead,将每个输入的特征图首先经过两个 RFAConv 卷积层,再通过用于回归的卷积层序列列表 cv2 和用于分类的卷积层序列列表 cv3 进行输出,RFAHead 在处理复杂且难以检测的小目标场景中可以显著增强模型的检测精度。结构如图 8 所示。

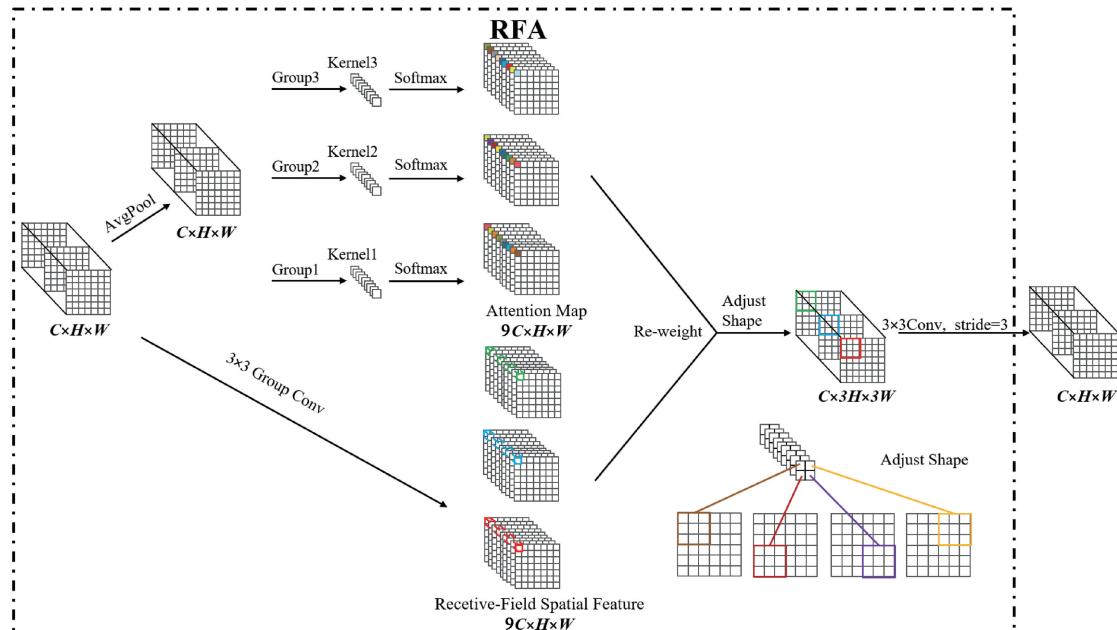


图 7 Receptive-Field Attention 结构

Fig. 7 Receptive-Field Attention architecture

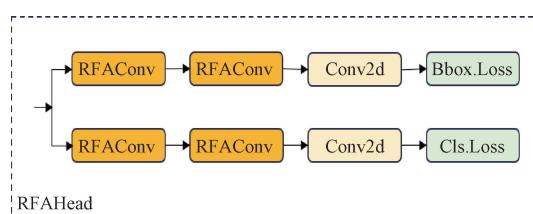


图 8 RFAHead 结构

Fig. 8 RFAHead architecture

### 3 实验结果与分析

#### 3.1 实验环境

本文实验环境如表 1 所示,输入图片分辨率为  $640 \times 640$ ,初始学习率为 0.01,衰减系数设为 0.0005。

表 1 实验环境及参数

Table 1 Experimental environment and parameters

名称	参数
操作系统	Linux
CPU	Intel(R) Xeon(R) Silver 4214R
GPU	NVIDIA GeForce RTX 3080 Ti
显存	12 GB
运行内存	32 GB
开发环境	Python 3.10
开发框架	PyTorch 2.1.0
CUDA	12.1

#### 3.2 数据集

本文选用了一个公开的开源数据集 Mendeley,数据集

涵盖了多种场景和光照条件, 包含了人员是否佩戴安全帽的图像, 涵盖了建筑工地常见场景以及各种复杂环境, 具有较强的代表性和广泛性。该数据集总共包含 5 000 张图片, 将其按照 7 : 1 : 2 的比例随机划分为训练集、验证集和测试集。

### 3.3 评估指标

为验证改进模型的性能, 采用召回率(recall, R)、精确率(precision, P)、平均精度均值(mean average precision, mAP)、参数量(params) 和计算量(giga floatingpoint operations per second, GFLOPs)作为模型评估指标。

召回率指标用于评估在安全帽佩戴检测任务中, 模型对实际佩戴安全帽样本的预测效果。它表示被模型正确识别为佩戴安全帽的样本占所有实际佩戴安全帽样本的比例, 其计算公式如下:

$$R = \frac{TP}{TP + FN} \quad (8)$$

精确率指标用于评估安全帽佩戴检测任务中, 模型将样本预测为佩戴安全帽时的准确性。它表示被模型正确预测为佩戴安全帽的样本数占所有预测为佩戴安全帽样本总数的比例, 其计算公式为:

$$P = \frac{TP}{TP + FP} \quad (9)$$

其中, TP 表示检测为真的正样本数量, FP 表示预测为真的负样本数量, FN 表示未检测到的正样本数量。

mAP 指标可分为两种形式: mAP@0.5 和 mAP@0.5-0.95。mAP@0.5 表示在 IoU 阈值固定为 0.5 时的平均精度, 而 mAP@0.5-0.95 则是在多个 IoU 阈值(从 0.5 到 0.95, 间隔为 0.05)下计算的平均精度值。IoU 是一种衡量预测框与真实框重叠程度的指标。计算公式为:

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (11)$$

参数量指的是网络模型中所有训练参数的总数, 计算量指模型每秒执行的浮点运算次数, 用于衡量模型的复

杂度。

### 3.4 结果与分析

#### 1) 消融实验

为了验证不同改进策略的优化作用, 以 YOLOv8n 模型为基准模型依次进行改进并训练对比, 进行不同改进方法之间的消融实验。结果如表 2 所示, 在主干网络中引入 CMUNeXtBlock 后精确率、召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 0.1%、3.4%、2.1% 和 1.7%, 计算量略微增加, 证明该模块利用深度可分离卷积和反向瓶颈设计在不增加参数量的同时增强模型对多尺度目标的感知力。引入 C2FICB 模块后召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 5.5%、3.3% 和 2.3%, 同时降低了参数量和计算量, 证明该模块通过融合不同通道和空间位置之间的信息, 轻量化的同时增强模型的特征交互能力。引入 P2 微尺度目标检测层进一步提取出丰富的小目标特征信息后精确率、召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 0.6%、4.6%、4.2% 和 1.7%, 增加了部分计算量。引入 RFAHead 后召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 3.0%、2.0% 和 1.7%, 参数量和计算量轻微上升, 该检测头根据输入特征图动态调整卷积核的感受范围, 对特征图进行加权处理, 从而优化空间特征表达。最终将每项改进融合在一个网络结构中, 相比于原始 YOLOv8, 改进后的模型召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 6.7%、5.2%、3.9%, 仅增长了部分参数量和计算量, 结果表明本文构建的算法能显著提升复杂场景下的安全帽目标检测精度, 验证了本文所提方法的有效性。

#### 2) 不同卷积模块效果对比

在模型主干网络的相同位置添加不同的卷积模块, 比较各个模块对 YOLOv8 模型检测安全帽准确度的影响, 实验在相同的硬件条件下进行, 实验结果如表 3 所示, 由表 3 可知, 模型引入 DualConv<sup>[20]</sup> 后召回率、mAP@0.5、mAP@0.5-0.95 分别提高了 2.4%、1.5%、1.4%, 但精确率下降了 1.1%, 减少了部分参数量和计算量。模型引入

表 2 消融实验结果

Table 2 Ablation experiment results

CMUNeXtBlock	C2FICB	P2	RFAHead	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%	Params/ 10 <sup>6</sup>	GFLOPs
×	×	×	×	87.2	72.1	80.3	49.2	3.1	8.2
√	×	×	×	87.3	75.5	82.4	50.9	3.1	8.5
×	√	×	×	86.8	77.6	83.6	51.5	3.0	8.1
×	×	√	×	87.8	76.7	84.5	51.9	3.0	12.5
×	×	×	√	87.2	75.1	82.3	50.8	3.9	8.4
√	×	√	×	87.8	77.3	84.7	52.4	3.2	13.1
√	×	√	√	87.0	77.5	85.4	53.0	4.1	11.3
√	√	√	√	86.9	78.8	85.5	53.1	3.8	10.9

DynamicConv<sup>[21]</sup>后召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 2.8%、1.8% 和 1.3%，精确率下降了 0.1%，参数量增加较多。模型引入 SPDConv<sup>[22]</sup>后精确率、召回率和 mAP@0.5-0.95 分别提高了 0.2%、2.2% 和 1.3%，但 mAP@0.5 下降了 0.7%，同时增加了较多参数量和计算

量。模型引入 CMUNeXtBlock 后精确率、召回率、mAP@0.5 和 mAP@0.5-0.95 分别提高了 0.1%、3.4%、2.1% 和 1.7%，仅增加了部分计算量。综合考虑模型的精度和复杂度，CMUNeXtBlock 能够在不显著增加模型复杂度的情况下提升检测效果，验证了 CMUNeXtBlock 的有效性。

表 3 不同卷积模块效果对比

Table 3 Comparison of effects of different convolution modules

模型	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%	Params/ $10^6$	GFLOPs
YOLOv8n	87.2	72.1	80.3	49.2	3.1	8.2
+DualConv	86.1	74.5	81.8	50.6	2.9	8.0
+DynamicConv	87.1	74.9	82.1	50.5	3.9	7.9
+SPDConv	87.4	74.3	79.6	50.5	3.8	8.8
+CMUNeXtBlock	87.3	75.5	82.4	50.9	3.1	8.5

### 3) 不同模型对比实验

将本文提出的改进算法与其他主流 YOLO 系列算法进行对比，评估本文改进算法的性能，结果如表 4 所示。由表 4 可知，YOLOv3-tiny、YOLOv7-tiny<sup>[23]</sup>模型 mAP 远低于本文改进算法，YOLOv7-tiny 的参数量和计算量也高于本文模型；YOLOv5n、YOLOv6n<sup>[24]</sup>、YOLOv8n、YOLOv10n 模型平均精度指标都落后于本文改进算法；与

YOLOv5s、YOLOv6s、YOLOv8s 模型相比，本文提出的改进算法在精度上表现出更优的性能，同时在参数量和计算量方面显著低于这些算法。

由以上对比实验数据可知，本文提出的改进算法的更适用于复杂的施工场景应用，显著提高了安全帽佩戴检测的平均精度，验证了本文提出的安全帽佩戴检测算法在小目标、目标密集、目标遮挡及复杂场景下目标检测任务中的有效性。

表 4 不同检测模型对比

Table 4 Comparison of different detection models

模型	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%	Params/ $10^6$	GFLOPs
YOLOv3-tiny	87.0	66.7	74.6	44.5	12.1	18.9
YOLOv5n	87.9	73.1	81.4	49.3	2.5	7.1
YOLOv5s	87.6	77.7	84.0	52.7	9.1	23.8
YOLOv6n	86.9	73.5	81.4	50.5	4.2	11.8
YOLOv6s	88.0	77.7	84.1	53.3	16.3	44.0
YOLOv7-tiny	89.2	70.1	79.6	46.9	6.1	13.1
YOLOv8n	87.2	72.1	80.3	49.2	3.1	8.2
YOLOv8s	86.9	78.1	84.4	53.0	11.1	28.5
YOLOv10n	87.7	77.2	83.1	52.2	2.7	8.4
本文算法	86.9	78.8	85.5	53.1	3.8	10.9

### 4) 检测结果对比分析

为了更直观的检验改进算法的性能优势，选择了数据集中部分遮挡、密集及光线昏暗等复杂场景下的图像检测对比，结果如图 9 所示。同时为进一步说明改进算法的有效性，将改进前后算法的各项评估性能指标进行对比，结果如图 10 所示。在图 9(a)中可以看出改进算法在低光照环境下检测效果有了明显提升，在图 9(b)和(c)中对于多人员多物体遮挡环境下的检测效果相比原算法改进算法

检测精度上升的同时漏检误检率也明显下降。从图 10 中可以看出改进模型相较于原算法前期提升迅速，在训练过程中始终高于 YOLOv8n，最终稳定在较高水平，在各项性能评估指标中皆优于原算法。

实验结果显示，本文提出的改进算法在遮挡密集及光线昏暗等复杂环境下展现出良好的检测效果。相比于原始 YOLOv8 模型，本文提出的算法准确率明显提升，检测置信度高于 YOLOv8n 的同时漏检率和误检率也显著降低。

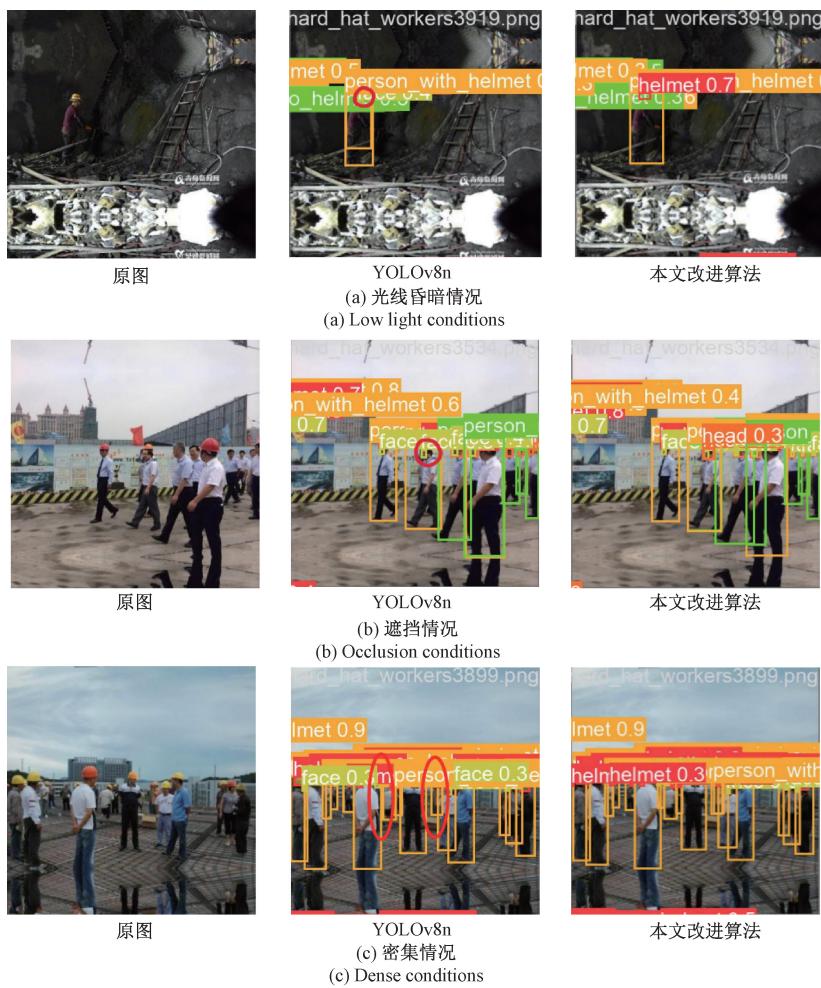


图 9 复杂环境检测效果对比

Fig. 9 Comparison of detection results in complex environment

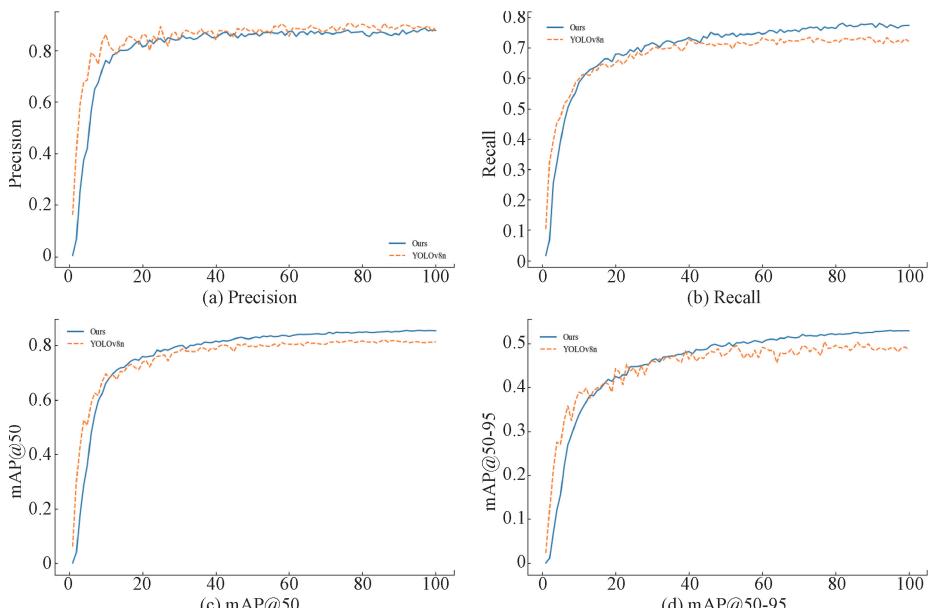


图 10 两种算法在 Mendeley 数据集上的评估指标曲线

Fig. 10 Evaluation metric curves of two algorithms on the Mendeley dataset

### 5) 其他改进方法对比分析

为验证本文改进方法的有效性和先进性。将本文方法与其他安全帽改进方法进行对比分析,结果如表 5 所示,图 11 从左到右依次为原图、文献[25]、文献[26]、文献[27]、文献[28]、文献[29]、本文方法的检测结果。文献[25]在 YOLOv5 模型中引入微尺度检测层,插入坐标注意力机制,用 EIOU 替代 CIOU 损失函数。提高模型面对小目标和目标遮挡的检测能力。但在图 11(b)中仍存在误检问题。文献[26]改进 YOLOv8 模型设计 GRC-C2f 结构,设计 DSASF 颈部结构,引入 Focal Modulation 模块,采用空间增强注意力模块解决小目标遮挡问题。但在图 11(a)中存在误检问题。文献[27]在 YOLOv8 模型中

引入更高分辨率的特征图并新增级联查询机制,采用更深层卷积替换 DeepSORT 中小型残差网络来强化外观信息提取能力。但在图 11(a)中出现漏检误检问题。文献[28]改进 YOLOv8 模型增加小目标检测头并且在特征提取网络中嵌入 Double Attention 注意力机制,将特征融合网络替换成跨层多尺度特征融合结构,采用 MPDIoU 损失函数解决小目标密集遮挡问题,但在图 11(b)中出现漏检误检问题。文献[29]改进 YOLOv10 模型引入 RepNMSC 结构,在 Backbone 部分改进 C2f 结构,Neck 部分采用 ERepGPN 结构实现融合小目标特征的目的,使用 Inner-Wise-MPDIoU 加快模型收敛,但同样在图 11(b)中存在漏检问题。

表 5 其他改进方法对比结果

Table 5 Comparison of results with other improvement methods

模型	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%	Params / 10 <sup>6</sup>	GFLOPs
文献[25]	86.4	69.2	75.4	45.7	2.28	11.7
文献[26]	87.9	74.6	84.1	51.2	4.3	13.1
文献[27]	86.7	72.6	77.8	48.1	10.9	36.8
文献[28]	86.9	74.6	83.3	49.8	4.4	12.5
文献[29]	87.8	75.8	83.9	52.6	2.7	9.1
本文模型	86.9	78.8	85.5	53.1	3.8	10.9

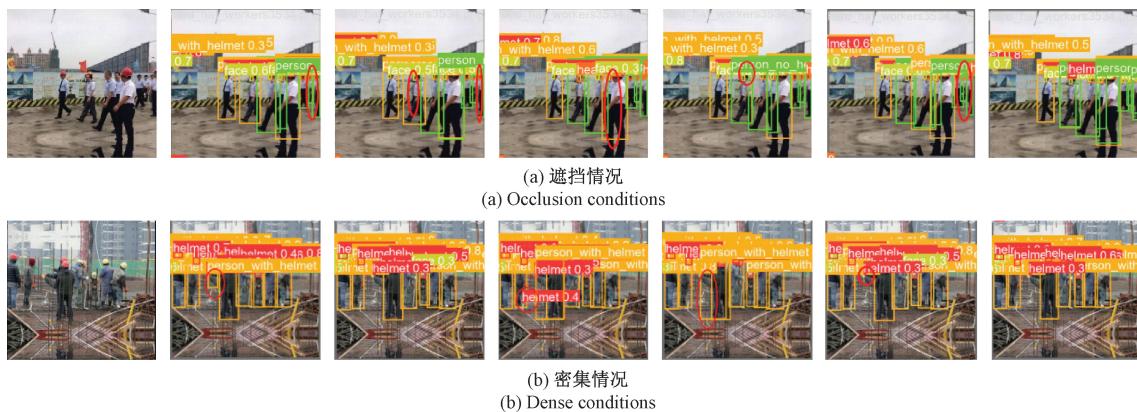


图 11 不同改进方法检测结果对比

Fig. 11 Comparison of detection results with different improvement methods

本文模型引入 CMUNeXtBlock 模块,设计 C2FICB 模块,引入 P2 微尺度目标检测层,提出 RFAHead 检测头。与其他改进模型相比,本文模型在应对小目标、密集目标、目标遮挡以及复杂环境时表现出较强的适应性,有效减少了误检和漏检的发生,同时在检测精度方面也取得了一定的提升。

## 4 结 论

为解决现有安全帽佩戴检测算法在处理小目标、目标密集、遮挡场景时,出现误检、漏检和检测精度低的问题。

本文提出了一种基于改进的 YOLOv8 安全帽佩戴检测算法。在 YOLOv8 主干网络中引入 CMUNeXtBlock 模块,设计 C2FICB 模块,引入 P2 尺度目标检测层,提出 RFAHead 检测头,增强算法在复杂场景下的特征提取能力,提升算法的检测精度。实验结果显示,与原始 YOLOv8 算法相比,本文提出的算法更适合小目标、目标密集、遮挡复杂场景的实际应用。未来将继续对本文算法改进优化,在保证精度的前提下使网络模型更加轻量化,利用剪枝蒸馏等方法对模型进行压缩,增强算法的实用性。

## 参考文献

- [1] ÖZÜAĞ S, ERTUĞRUL Ö. Enhanced occupational safety in agricultural machinery factories: artificial intelligence-driven helmet detection using transfer learning and majority voting [J]. Applied Sciences, 2024, 14(23):11278-11278.
- [2] JIRAKITPUWAPAT W, DUBEY P, PRASERTSUK N, et al. Convergence property of Nesterov-accelerated adaptive moment estimation with safety helmet detection and classification in smart industry application[J]. Mathematical Methods in the Applied Sciences, 2024, 47(16):12650-12667.
- [3] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision (ICCV), 2015: 1440-1448.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th European Conference on Computer Vision, 2016:21-37.
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016:779-788.
- [6] 赵红成,田秀霞,杨泽森,等.改进 YOLOv3 的复杂施工环境下安全帽佩戴检测算法[J].中国安全科学学报,2022,32(5):194-200.
- ZHAO H CH, TIAN X X, YANG Z S, et al. Safety helmet wearing detection algorithm in complex construction environment based on improved YOLOv3[J]. China Safety Science Journal, 2022, 32(5):194-200.
- [7] YANG B, WANG J. An improved helmet detection algorithm based on YOLOv4[J]. International Journal of Foundations of Computer Science, 2022, 33: 887-902.
- YANG Y B, LI D. Lightweight helmet wearing detection algorithm of improved YOLOv5 [J]. Computer Engineering and Applications, 2022, 58(9): 201-207.
- [8] 杨永波,李栋.改进 YOLOv5 的轻量级安全帽佩戴检测算法[J].计算机工程与应用,2022,58(9):201-207.
- YANG Y B, LI D. Lightweight helmet wearing detection algorithm of improved YOLOv5 [J]. Computer Engineering and Applications, 2022, 58(9): 201-207.
- [9] 王新良,王璐莹.特征增强的低照度爆破现场安全帽检测算法[J].计算机工程,2025,51(3):252-260.
- WANG X L, WANG L Y. Helmet detection algorithm based on feature enhancement in low light blasting scene [J]. Computer Engineering, 2025, 51 ( 3 ): 252-260.
- [10] 李凤英,罗超.基于深度学习的矿山作业安全帽穿戴规范性识别算法[J].有色金属(矿山部分),2023,75(4): 7-13.
- LI F Y, LUO CH. Normative recognition algorithm for safety helmet wearing in mining operations based on deep learning[J]. Nonferrous Metals(Mining Section), 2023,75(4):7-13.
- [11] 王迎龙,孙备,丁冰,等.BG-YOLO:复杂大视场下低慢小无人机目标检测方法[J].仪器仪表学报,2025, 46(2):255-266.
- WANG Y L, SUN B, DING B, et al. BG-YOLO: A low-altitude slow-moving small UAV targets detection method in complex large field of view [J]. Chinese Journal of Scientific Instrument, 2025, 46(2):255-266.
- [12] ZHANG L, SUN ZH, TAO H, et al. Research on mine-personnel helmet detection based on multi-strategy-improved YOLOv11 [J]. Sensors, 2024, 25(1):170-170.
- [13] 帅勃宇,张雅丽.改进 YOLOv8 的电动自行车电池检测算法[J].电子测量技术,2025,48(5):147-155.
- SHUAI B Y, ZHANG Y L. Improved YOLOv8 electric bicycle battery detection algorithm [J]. Electronic Measurement Technology, 2025, 48 ( 5 ): 147-155.
- [14] XIE H, JIA X J, YU Q CH, et al. Helmet and license plate detection for cyclists based on improved YOLOv5 [J]. Journal of Optoelectronics • Laser, 2024, 35(4):396-404.
- [15] BOCHKOVSKIY A, WANG CH Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [16] 张瑞芳,刘占占,程小辉,等.基于改进 YOLOv8 的无人机红外目标检测算法[J].电子测量技术,2025, 48(7):46-54.
- ZHANG R F, LIU ZH ZH, CHENG X H, et al. UAV infrared target detection algorithm based on improved YOLOv8[J]. Electronic Measurement Technology, 2025, 48(7):46-54.
- [17] 郭志聪,张雷.基于改进 YOLOv8 的低照度煤矿传送带异物识别算法[J].电子测量技术,2024,47(21): 188-196.
- GUO ZH C, ZHANG L. Foreign object recognition algorithm of low-light coal mine conveyor belt based on improved YOLOv8 [J]. Electronic Measurement Technology, 2024,47(21):188-196.
- [18] JU X J, LIANG X D. Railway catenary insulator recognition based on improved faster R-CNN [J]. Automatic Control and Computer Sciences, 2023, 56(6):553-563.
- [19] ZHANG X, LIU CH, YANG D, et al. RFACConv:

- Innovating spatial attention and standard convolutional operation[J]. ArXiv preprint arXiv:2304.03198,2023.
- [20] ZHONG J CH, CHEN J Y, MIAN A. DualConv: Dual convolutional kernels for lightweight deep neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022,34(11): 9528-9535.
- [21] CHEN Y P, DAI X Y, LIU M CH, et al. Dynamic convolution: Attention over convolution kernels[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2020:11027-11036.
- [22] SUNKARA R, LUO T. No more strided convolutions or pooling: A new CNN building block for low-resolution images and small objects [C]. Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2022: 443-459.
- [23] WANG CH Y, BOCHKOVSKIY A, LIAO H Y 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.
- [24] LI CH Y, LI L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[J]. ArXiv preprint arXiv:2209.02976,2022.
- [25] 韩锟栎,张涛,彭波,等.基于改进YOLOv5的安全帽检测算法[J].现代电子技术,2024,47(5):85-92.  
HAN K D, ZHANG T, PENG B, et al. Safety helmet detection algorithm based on improved YOLOv5[J]. Modern Electronics Technique, 2024,47(5):85-92.
- [26] 邱云飞,腰瑞琳,金海波,等. HD-YOLO:复杂场景下安全帽佩戴检测算法[J]. 安全与环境学报, 2025, 25(1):165-174.  
QIU Y F, YAO R L, JIN H B, et al. HD-YOLO: A helmet detection algorithm for complex scenarios[J]. Journal of Safety and Environment, 2025, 25 (1): 165-174.
- [27] 丁玲,缪小然,胡建峰,等.改进YOLOv8s与DeepSORT的矿工帽带检测及人员跟踪[J].计算机工程与应用,2024,60(5):328-335.  
DING L, MIAO X R, HU J F, et al. Improved miner chin strap detection and personnel tracking with YOLOv8s and DeepSORT[J]. Computer Engineering and Applications, 2024,60(5):328-335.
- [28] 陈亮,王璇,雷坤.复杂场景下跨层多尺度特征融合安全帽佩戴检测算法[J/OL].计算机应用,1-11[2025-04-05]. <http://kns.cnki.net/kcms/detail/51.1307.tp.20241017.1033.002.html>.  
CHEN L, WANG X, LEI K. Helmet wearing detection algorithm for complex scenarios based on cross-layer multi-scale feature fusion[J/OL]. Journal of Computer Applications, 1-11 [2025-04-05]. <http://kns.cnki.net/kcms/detail/51.1307.tp.20241017.1033.002.html>.
- [29] 高立鹏,周孟然,胡锋,等.基于REIW-YOLOv10n的井下安全帽小目标检测算法[J/OL].煤炭科学技术,1-13[2025-04-05]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.  
GAO L P, ZHOU M R, HU F, et al. Small target detection algorithm for underground helmet based on REIW-YOLOv10n [J/OL]. Coal Science and Technology, 1-13[2025-04-05]. <http://kns.cnki.net/kcms/detail/11.2402.td.20240919.1902.003.html>.

### 作者简介

杨瑞君,博士,副教授,主要研究方向为计算机视觉、机器嗅觉。

E-mail:yangruijun@sit.edu.cn

李悦东(通信作者),硕士研究生,主要研究方向为计算机视觉、目标检测。

E-mail:18119661203@163.com

叶璕,博士,副教授,主要研究方向为环境科学、水质基准。

E-mail:yejinganna@sit.edu.cn