

RL-YOLO:改进 YOLOv8n 的安全帽佩戴检测算法

杨焱磊¹ 阮景奎¹ 王宸¹ 闫伟伟²

1 湖北汽车工业学院 机械工程学院 2 驰田汽车股份有限公司

DOI:10.12238/acair.v2i4.10357

[摘要] 在工业生产中,佩戴安全帽是对施工人员头部安全的一项重要措施。针对改装车间工人安全帽佩戴不规范、设备繁多、人员工作密集等特点,设计基于YOLOv8n模型的安全帽佩戴检测算法。算法推出重校准金字塔网络(Re-CalibrationFPN)改进原模型的颈部网络,新增小目标特征信息层,加强了模型的深层与浅层交互能力,从而增加模型检测的准确率;同时使用轻量化的检测头LSD(Lightweight Shared Detection Head),通过使用共享卷积的方式减少模型参数量与计算量,使模型便于安装部署到终端;结合使用Wise-IoU和Powerful-IoUv2的思想改进损失函数,引入新的惩罚机制措施,提升模型处理复杂样本的能力。实验结果表明,改进后的RCLS-YOLOv8模型在公开数据集SHWD(Safety Helmet Wearing Dataset)上P降低了0.2%,R、mAP@0.5分别提升了3.9%和2.9%,能够满足检测和部署要求。

[关键词] YOLOv8; 实时监测; 重校准金字塔网络; LSD检测头; 损失函数

中图分类号: TP391.41 **文献标识码:** A

RL-YOLO: Improve YOLOv8n's helmet wearing detection algorithm

Yaolei Yang¹ Jingkui Ruan¹ Chen Wang¹ Weiwei Yan²

1 School of Mechanical Engineering, Hubei University of Automotive Industry 2 Chitian Automobile Co., Ltd.

[Abstract] In industrial production, wearing a helmet is an important measure for the head safety of construction personnel. According to the characteristics of non-standard helmet wearing, numerous equipment and intensive personnel work, the helmet wearing detection algorithm based on YOLOv8n model is designed. The algorithm calibration pyramid network (Re-CalibrationFPN) to improve the neck network of the original model, Add a small target feature information layer, Strengthening the ability of the model to interact between the deep and shallow layers, Thus increasing the accuracy of the model detection; Also using a lightweight test head LSD (Lightweight Shared Detection Head), By reducing the number of model parameters and the computation by using shared convolution, Make the model easy to install and deploy to terminals; Combining the thought improvement loss function using Wise-IoU and Powerful-IoU v 2, Introducing new punishment mechanism measures, Improve the ability of the model to handle complex samples. The experimental results show that the improved RCLS-YOLOv8 model reduced P by 0.2% on the public data set SHWD (Safety Helmet Wearing Dataset), and R and mAP @ 0.5 increased by 3.9% and 2.9%, respectively, which can meet the detection and deployment requirements.

[Key words] YOLOv8; real-time monitoring; recalibrated pyramid network; LSD detection head; loss function

引言

随着现代工业领域的不断发展,工人需要运用各种高精度、高强度和高危险的复杂机械进行作业,其工作特性决定了安全生产管理的重要性。其中,佩戴安全帽等防护装备是保护工人生命安全的第一道也是最后一道防线。并且由于技术的不断进步和工艺的不断升级,从高空坠物、机械碰撞到飞溅的碎屑等汽车改装车间的安全隐患也日益多样化,因此实时检测工人是否佩

戴安全帽成为了企业管理中不可或缺的一环。

传统的人工检测方法不仅效率低,而且漏检问题严重。随着人工智能的普及以及科学技术的进步,基于深度学习的目标检测技术逐渐被应用于各个领域内的检测识别任务。针对工程作业背景条件下速度快,精度高的实时监测要求,以SSD^[1]系列、YOLO^[2]系列为代表的单阶段(one-stage)算法相较于以R-CNN^{[3][4]}系列为代表的两阶段(two-stage)算法省去了生成先

验框的步骤,直接在候选框内进行分类和定位操作,所以在检测速度上更快一筹也更符合检测安全帽的条件要求。Yang S等^[5]引入了交叉熵损失函数、反卷积和非极大抑制^[6]对SSD进行了改进,提高了检测精度,减少了模型的参数数量和计算量。Yang W等^[7]对YOLOv3的特征融合方法进行了改进,采用上采样方法融合特征,并采用迁移学习和BN^[8]进行训练,提高了检测准确率。宋晓凤^[9]等在YOLOv5模型的主干网络中引入注意力机制并替换主干网络中原有残差块,达到增强细粒度融合的能力,提高了算法的精度和速度。杨大为等^[10]在YOLOv7算法中引入卷积块注意力机制,同时增加一个小目标层,将浅层网络特征与深层网络特征融合,提高安全帽佩戴检测精度。Dong等人^[11]利用实时定位系统和虚拟系统来实现工人的位置跟踪,继而判定工人是否佩戴安全帽,并判断是否发出警报。戚玲琰等人改进了YOLOv7网络的MPConv模块和CIoU损失函数,利用ACmix模块加强对小目标的检测,使得小目标误检、漏检情况得到明显改善,但是实际应用中的检测精度仍有待改善^[12]。Li等人^[13]通过向YOLOv8中引入Bi-PAN-FPN的思想提高不同尺度间的特征融合,并用GhostblockV2结构代替部分卷积模块,得到了精度上的大幅提升,但在所有的小目标类别中无法获得比其他模型更好的结果^[14]。

综上所述,在终端性能与硬件资源受限的情况下,要想设计出符合安全帽检测工况的算法模型,就必须同时兼顾速度与精度。本文以YOLOv8n模型为基础,提出一种重校准金字塔特征网络(Re-CalibrationFPN)^[15]改进原模型的颈部网络,增强原模型浅层与深层交互能力,并增强模型特征融合的能力;提出一种更加轻量化的检测头来优化模型的参数量和计算量的同时增加一个小目标检测层,进一步增强特征融合能力,使得模型的泛化性与鲁棒性得到一定程度的增强;最后优化改进原模型的IoU,使用Wise-IoU^[16]的思想改进PIoU^[17]函数,改善模型检测边框回归效果,提升模型处理复杂样本的能力。

1 YOLOv8模型

YOLOv8是ultralytics公司发布,在图像分类、物体检测和实例分割任务上展现出了卓越性能的最新稳定应用的版本,其提供了一个全新的SOTA模型,包括P5×640和P6×1280分辨率的目标检测网络和基于YOLACT的实例分割模型,基于缩放系数,分别有n、s、m、l、x五个不同大小的版本,能够满足大部分的检测任务。由于安全帽检测终端的限制,本文主要选用的是体积最小精度较低的YOLOv8n版本,主要由骨干网络(Backbone)、颈部网络(Neck)、头部网络(Head)组成。

骨干网络(Backbone)和颈部网络(Neck)主要是将YOLOv5的C3结构替换成梯度流更加丰富的c2f模块,其作用就是通过两个卷积层对输入数据进行特征转换,在将输入的数据分为两个分支进行处理,然后在不同的通道维度上对不同的分支进行拼接融合操作,使模型能够根据不同的对象调整参数,从而提升模型的性能。头部网络(Head)最大的变化就是从原先的耦合头变成了当下流行的解耦头结构,分离了分类和回归分支,并且取消了

obj分支,提高模型的收敛能力。在loss的计算策略上抛弃了以往的IoU的匹配,转而使Task-Aligned Assigner正负样本匹配方式。公式如式(1)所示:

$$t = s^{\alpha} \times u^{\beta} \quad (1)$$

s和u为分类得分和IoU(Intersection over Union)值, α 和 β 为权重超参数。

2 改进的YOLOv8算法

安全帽的应用场景大部分诸如建筑工地,改装车间,大型机械施工等,存在遮挡,光照过强或过弱,人员密集等特点,对原模型的检测精度与速度产生了极大的影响。针对此类问题,做出以下改进:

(1)提出了SBA(Selective Boundary Aggregation)模块改造传统的FPN结构,得到重校准金字塔网络结构(Re-Calibration FPN),增强模型的浅层与深层交互能力。

(2)通过使用轻量化检测头LSD(Lightweight Shared Detection Head)来提升检测头定位和分类的性能。通过使用共享卷积,使模型更加的轻便可靠。

(3)结合wise-IoU与PIoU两大损失函数的优点进行改造优化,提出W-PIoU从而改进原模型边框回归损失函数,提升模型的学习能力以及处理复杂样本的能力。结构模型如图1所示:

2.1 Re-CalibrationFPN重校准金字塔网络

YOLOv8的Neck部分主要是对来自Backbone的特征进行融合处理,采用将特征金字塔网络(FPN)与路径聚合网络(PAN)相结合的思想,在丰富细节的同时,使得模型浅层语义更少,同时在减少失真的前提下,能够拥有更明显的边界特征。此外,深层蕴藏着更加丰富的物质语义信息。因此,直接融合低级具有高级特性的特性可能导致冗余和不一致。为了解决这个问题,本文提出了SBA模块,它有选择地聚合边界信息和语义信息来描绘更细粒度的物体轮廓和重新校准物体的位置。相比传统的FPN结构,SBA模块引入了高分辨率和低分辨率特征之间的双向融合机制,使得特征之间的信息传递更加充分,进一步提升了多尺度特征融合的效果。同时通过自适应的注意力机制,根据特征图的不同分辨率和内容,自适应地调整特征的权重,从而更好地捕捉目标的多尺度特征。

与以往的融合方法不同,本文通过采用一重新校准注意力机制RA(Re-Calibration Attention),它在融合前自适应地从两个输入Fs, Fb中获取相互表示。并将浅层和深层信息通过不同的方式输入到两个RA模块中,以弥补高级语义特征缺失的空间边界信息和低层特征缺失的语义信息缺失。最后,两个RA模块的输出在3×3卷积后被连接起来。该聚合策略实现了不同特征的鲁棒组合,并对粗糙特征进行了细化。RA模块函数过程可以表示为:

$$T_1' = W_{\theta}(T_1) \quad T_2' = W_{\phi}(T_2) \quad (2)$$

$$P(T_1, T_2) = T_1' \cdot T_1 + T_2' \cdot T_2 \cdot (-T_1') + T_1 \quad (3)$$




图1 RCLS-YOLOv8模型结构图

其中 T_1 、 T_2 为输入特征, W_θ 、 W_ϕ 为对输入的特征采用一个核大小为 1×1 的卷积运算进行两次线性映射和sigmoid函数运算后将通道数降至32层, 得到特征图 T_1 和 T_2 。然后将不完整的粗略的特征图进行估算并重新细化为一个完整的精确的预测图^[18]。过程如图2:




图2 Re-Calibration Attention Uni

因此, SBA模块公式可以表达为式(4):

$$Output = Conv_{3 \times 3}(Concat(P(F^s, F^b), P(F^b, F^s))) \quad (4)$$

其中 $Conv_{3 \times 3}$ 为具有批量归一化和ReLU激活层的 3×3 卷积。 F^s 在融合了来自编码器的第三、第四层后包含了深层语义信息, F^b 是来自主干的具有丰富边界细节的第一层。Concat是沿通道尺寸的连接操作。Output是SBA模块的输出。结构如图3:




图3 Selective Boundary Aggregation

2.2 LSD轻量化共享检测头

区别于YOLOv5的耦合头, YOLOv8使用了解耦头(Decoupled-Head)继续预测, 将回归分支和预测分支分离, 并针对回归分支使用了Distribution Focal Loss策略中提出的积分形式表示法。虽然使得网络的训练和推理更加精确, 但是缺点就是引入了大量的冗余计算, 并且传统的卷积操作也无法对特定目标的信息进行有效的聚合。为了提高模型的表达能力以及减少模型的参数, 本文提出了LSD轻量化检测头, 原先的检测头针对不同的检测层级分别使用独立的检测头, 这无疑使得模型的计算更加

复杂, 从而导致模型参数利用率低下, 而诸如RetinaNet, FCOS等检测器应用共享检测头的经验已经告诉我们, 在相似的尺度下, 物体所表达出来的特征是相似的。因此本文通过引入共享卷积, 可以在计算量相同的情况下对不同的特征进行计算, 从而可以大幅减少参数数量, 使得模型更轻便。但是不同层级之间的特征统计仍然存在一定的差距, 所以还需要进行进一步的BN归一化处理, 同时为了应对每个检测头所检测的目标尺度不一致的问题, 使用Scale层对特征进行缩放。

通过上述方法, 特别是在资源受限的设备上, 可以让检测头做到参数数量更少、计算量更少的情况下, 尽可能减少精度的损失。其模型结构如图4所示:




图4 LSD轻量化共享检测头

2.3 W-PIoU损失函数

在目标检测中, IOU(Intersection Over Union)是衡量两个矩形之间重叠程度的一种重要指标, 通过引入并优化损失函数, 从而使预测边界框与真实边界框之间的IOU差异达到最小, 是提升检测准确性的关键策略。公式如下:

$$IoU = \frac{|b \cap b^{gt}|}{|b \cup b^{gt}|} \quad (5)$$

损失函数的选择又是十分关键, 经过不断迭代演变, 出现了如GIoU、DIoU、CIoU、EIoU、SIoU、WIoU、shapeIoU、mpdIoU等多种多样的IoU, YOLOv8模型则还是采用了非常经典的CIoU, 计算公式如式:

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (6)$$

其中, $v = \frac{4}{\pi^2} (\arctan \frac{w}{h})^2$ 是用来衡量长宽比一致性的参数,

$\alpha = \frac{v}{(1 - IoU) + v}$ 为平衡参数, ρ 表示预测框与真实框中心点的

欧氏距离。CIoU损失函数通过综合考量位置、形状及方向等因素, 全面优化目标框特征学习, 从而提升模型在复杂场景下的检测性能。但是在预测框和gt框的长宽比相等的情况下, 补偿则不生效, 并且 w, h 相对于 v 的梯度是一对相反数, 即不能同时增大或者缩小。这就造成模型对于低质量标注, 噪音大, 背景复杂的目标的检测效果不良好。

截至目前为止, 基于IoU的损失函数都同CIoU一样, 或多或少存在一些不合理的惩罚因子, 从而导致锚框回归问题, 收敛速度也非常缓慢。针对这些问题, Wise-IoU提出动态非单调聚焦机制的思想, 使用“离群度”替代IoU对锚框进行质量评估, 并提供

明确的梯度增益分配策略,有效降低了低质量示例产生的有害梯度,提高整体检测的性能。其公式如下所示:

$$L_{WIoU} = rR_{WIoU}L_{IoU} \quad (7)$$

$$R_{WIoU} = \exp\left(\frac{(x-x^{gt})^2 + (y-y^{gt})^2}{(w_g^2 + h_g^2)^s}\right) \quad (8)$$

$$\beta = \frac{L_{IoU}^*}{L_{IoU}} \in [0, +\infty) \quad (9)$$

$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (10)$$

其中, w_g, h_g 是最小封闭框的大小,上标*表示将数据从计算图中分离出来。

通过式可知, WIoU其实就是通过构造两层距离注意力机制,从而削弱距离,长宽比等几何因素对示例的惩罚效果,从而增加模型的泛化能力,在通过构造离群值 β 函数使其能够通过调整不同的超参数 α 和 δ 来适应不同的模型和数据集,其在低质量标注的小目标对象上的效果更加显著。

Powerful-IoU则更聚焦于结合目标尺寸来自适应惩罚因子和基于锚框质量的梯度调整函数,使锚框能够沿着高效路径进行回归并且能够更快的收敛。其公式如下:

$$p = \left(\frac{DW_p}{W_r} + \frac{DW_r}{W_r} + \frac{Dh_r}{H_r} + \frac{Dh_p}{H_r}\right) \quad (11)$$

$$L_{PIoU} = 3 \cdot (\lambda e^{-p}) \cdot e^{-(\lambda e^{-p})^2} \cdot \left(1 - \frac{1}{L_{IoU}} + 1 - e^{-p^2}\right) \quad (12)$$

$(p > 0)$

在公式中, $L_{PIoU-v2}$ 中选用 e^{-p} 作为惩罚项因素,当预测框与

真实框完全重合时, $p=0$, 此时, $e^{-p} = 1$ 当预测框与真实框偏离时,惩罚项 p 会逐渐增大,表示锚框的精确度在降低。在惩罚项因素 p 中,选用“ $-p$ ”作为幂次数,使得 p 增大时,惩罚项因素会有一定的梯度变化,但是始终在区间 $(0, 1]$ 中处于缓慢变化趋势,可以有效避免为减少惩罚项函数值导致锚框的无意义扩大。同时, $L_{PIoU-v2}$ 整体在预测框与真实框接近完全重合,或接近完全不重合,即 p 趋近于0或 p 值较大时函数值变化幅度较小,当预测框与真实框有一定面积重合,即 p 处于区间中心阶段时,梯度变化幅度较大,能够提高模型对于精确度适中的锚框的关注度,从而提升边界框收敛速度,提升预测框精准度,其在中等锚框目标对象上的效果更好。

本文根据所选安全帽对象,应用场景噪音大,目标小的特点进行创新,集合两种IoU的优点,提出W-PIoU来更好的关注中小目标,来更好的解决锚框关注问题,实验也证明了改进对检测效果的提升非常明显。公式如下:

$$L_{W-PIoU} = rR_{WIoU}L_{PIoU-v2} \quad (13)$$

3 实验设计与结果

3.1 数据集与实验环境

本实验采用公开安全帽佩戴数据集SHWD (Safety-Helmet-Wearing Dataset) 进行实验。该数据集包含7581张图片,为确保数据的泛化性以及应用的准确性,在某公司工作车间在不同时间不同光照环境下采集514张图片对数据集进行扩充,得到共8095张图片,按照戴头盔和不戴头盔两种类别,使用LabelImg对图片进行手动标注,采用随机分配的方式,将数据以7:1:2的比例分成训练集、测试集和验证集。

3.2 实验环境

本文采用Linux ubuntu 18.04操作系统,CPU采用22vCPU AMD EPYC 7T83 64-Core Processor, GPU采用NVIDIA RTX 4090 (24GB), 编程语言Python3.8, 学习框架Pytorch 2.0, CUDA 11.8。模型训练参数如表1所示:

表1 训练参数

参数	设置
epochs	100
batch	32
images	640
workers	8

续表1 训练参数

close_mosaic	10
lrf	0.01
optimizer	SGD

3.3 评价指标

本文采用精确率(Precision)P、召回率(Recall)R、平均精度(mean Average Precision)MAP、参数量(Params)、浮点计算量(GFlops)作为评价指标, mAP@0.5表示IoU设为0.5时的平均精确度, mAP@0.5:0.95表示IoU从0.5到0.95,步长为0.05时的平均精确度,公式如下:

$$P = \frac{T_p}{T_p + F_p} \quad (14)$$

$$R = \frac{T_p}{T_p + F_n} \quad (15)$$

$$AP = \int_0^1 P(R) dR \quad (16)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (17)$$

其中, TP(True Positive)表示正确检测到的目标数量, FP(False Positive)表示错误检测到的目标数量, FN(False

Negative) 表示未检测到的目标数量。

3.4 消融实验

为了更加清晰的表现改进内容对于模型的优化程度,在相同的数据集和实验条件下进行此次消融实验,结果如表2所示。由B、D可知,在只应用LSD检测头的改进内容后,参数量和计算量相较于原始模型分别降低了23%和25%左右,模型轻量化程度得到了很大的加强,而同时应用两种改进内容的参数量相较于原始模型差距在3%左右,计算量则仅仅增加2.3G的浮点数,模型的轻量化与准确性也能够得到有效的保证;C在使用优化后的W-PIoU检测框损失函数后,在不改变模型大小和计算量的同时,性能提升0.9%左右,效果非常显著。从D、E、F将不同的改进方法分别组合进行实验的结果来看,各改进性能都能够产生一定的化学作用从而对原模型进行优化。最终将所有改进内容应用于原模型中,虽然P下降了0.2%,但是R%和mAP@0.5分别增加了3.9%和2.9%,在性能得到了比较大的提升的同时还能兼顾模型的轻量化程度,对于应用部署移动端具有非常大的作用,说明了此次改进的有效性,能够更好的完成目标检测任务。

表2 消融实验结果

Models	Re-Calibration	LSD	W-PIoU	P%	R%	mAP@0.5	Parameters	GFLOPs/G
Baseline				92.7	84	90.7	3006038	8.1
A	✓			93	85.8	93	3767720	15.1
B		✓		91.2	84.3	90.8	2362453	6.5
C			✓	92.3	85.1	91.6	3006038	8.1
D	✓	✓		91.7	88.8	92.7	3186598	10.4
E	✓		✓	93.1	87.1	93.9	3761080	14.9
F		✓	✓	92.2	85.3	91.4	2342453	6.5
G	✓	✓	✓	92.5	87.9	93.6	3186598	10.4

3.5 对比实验

判断一个目标检测模型的好坏,通常是通过分析模型的内存占用,模型大小,准确度等方面进行。轻量化与高精度度则是判断一个模型是否适合应用于移动端或者嵌入端设备的基本条件。将各经典目标检测模型在同样的实验平台与改进后的RCLS-YOLO进行测试,更直观地感受模型的改进效果以及算法的优越性,对比效果如表3所示。

由表3可知,传统模型中YOLOv8s虽然表现出了最佳的检测精确度,但模型参数量和计算量太大,对于部署内存量少,算力不足的移动设备难度较高,而改进后的模型不仅能够在准确率上比肩s版本甚至准确率上升了0.5%,足以能够说明模型改进的效果。YOLOv5s模型虽然更加的轻量化,但是在检测性能上略显不足,且版本过于老旧,开发潜力不足,满足不了视觉检测任务的性能要求。而YOLOv7版本不仅是在计算量上还是准确率上都明显不如其他模型优秀,说明YOLOv7版本不适用于此次检测目标任务。

本文的改进模型不论是在准确率还是轻量化程度上,都表现非常优秀,精度上能够对标最高的YOLOv8s,轻量化程度上能够对标YOLOv8n版本,这一结果表明,本文提出的RC重校准金字塔网络、LSD轻量化检测头和W-PIoU损失函数,能够有效的提升算法的精确度以及轻量化程度。在存储空间小,资源受限的设备上的应用潜力巨大,为工厂车间实时监测佩戴安全帽情况提供了更灵活可靠的方案。

表3 对比算法实验结果

Models	P%	R%	mAP@0.5	Parameters	GFLOPs/G
YOLOv5s	92.2	83.5	90.6	2508854	7.2
YOLOv7	91.3	81.3	88.9	37200095	105.1
YOLOv7-tiny	90.6	81.6	87.9	30691232	78.2
YOLOv8n	92.7	84	90.7	3006038	8.1
YOLOv8s	93.2	87.2	93.1	11166544	28.8
Ours	92.5	87.9	93.6	3186598	10.4

4 结语

针对安全帽主要应用于复杂多变的工作环境中这一特点,本文通过一系列针对YOLOv8n算法的优化措施,提出RELS-YOLO算法,提高了算法在安全帽佩戴检测任务中的表现。首先改进原有的金字塔网络结构,提出Re-CalibrationFPN重校准金字塔网络结构,极大的改善了模型的精确度,其次,创新性的引用共享卷积的思想重新设计出LSD轻量化共享检测头,使模型的轻量化程度得到极大增强,最后,根据检测目标背景复杂,目标小的特点改进损失函数,提出W-PIoU,通过引入两个惩罚项,使模型更加精确。这些改进不仅提高了检测的精度,还进一步降低了误检和漏检率,为安全生产提供了更加可靠的保障,在保持高性能的同时,也实现了算法的低延迟运行,满足了实时检测的需求。

展望未来,将继续深化对目标检测算法及其在安全帽佩戴检测领域应用的研究,致力于探索更多前沿技术,如自监督学习、注意力机制等,以进一步提升算法的智能化水平和泛化能力。我们相信,随着技术的不断进步与创新,RELS-YOLO在安全帽佩戴检测乃至更广泛的目标检测领域将展现出更加广阔的应用前景,为构建更加安全、智能的社会环境贡献力量。

[参考文献]

- [1]HOSHINO W,SEO J,YAMAZAKI Y.A study for detecting disaster victims using multi-copter drone with a thermographic camera and image object recognition by SSD[C]// 2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics(AIM),2021:162-167.
- [2]SORBELLI F B, PALAZZETTI L, PINOTTI C M. YOLObased detection of halyomorpha halys in orchards using RGB cameras and

drones[J]. Computers and Electronics in Agriculture, 2023, 213:108228.

[3]PIRASTE H, RASHIDI P, RASTIVEIS H, et al. Developing an algorithm for buildings extraction and determining changes from airborne LiDAR, and comparing with R-CNN method from drone images[J]. Remote Sensing,2019,11(11): 1272.

[4]SEO D M, WOO H J, KIM M S, et al.Identification of asbestos slates in buildings based on faster region-based convolutional neural network (Faster R-CNN) and drone-based aerial imagery[J]. Drones, 2022,6(8):194.

[5]YANG S D,CHEN Z H, MA X M,etal.Real-time high-precision pedestrian tracking: a detection-tracking-correction strategy based on improved SSD and cascade R-CNN[J]. Journal of Real-Time Image Processing,2022,19(2):287-302.

[6]GUO C S, CAI M,YING N,etal.ANMS:attention-based non-maximum suppression[J].Multimedia Tools and Applications, 2022,81(8):11205-11219.

[7]YANG W, ZHOU G L, GU Z W,etal.Safety helmet wearing detection based on an improved YOLOv3 scheme[J]. International Journal of Innovative Computing, Information and Control, 2022,18(3):973-988.

[8]WANG J R,LI S M,AN Z H,etal.Batch-normalized deep neural networks for achieving fast intelligent fault diagnosis of machines[J]. Neurocomputing,2019,329:53-65.

[9]宋晓凤,吴云军,刘冰冰,等.改进YOLOv5s算法的安全帽佩戴检测[J].计算机工程与应用,2023,59(2):194-201.

[10]杨大为,张成超.基于改进YOLOv7的安全帽佩戴检测算法[J].沈阳理工大学学报,2024,43(01):16-21.7.

[11]Dong S, He Q,Li H,etal.Automated PPE misuse identification and assessment for safety performance enhancement[M]// ICCREM2015,2015:204-214.

[12]戚玲珑,高建瓴.基于改进YOLOv7的小目标检测[J].计算机工程,2023,49(1):41-48.

[13]LI Y,FAN Q,HUANG H, et al. A modified YOLOv8 detection network for UAV aerial image recognition[J].Drones,2023,7(5): 304.

[14]潘玮,韦超,钱春雨,杨哲.面向无人机视角下小目标检测的YOLOv8s改进模型[J].计算机工程与应用,2024,60(9):142-150.

[15]Feilong Tang,Qiming Huang,Jinfeng Wang,Xianxu Hou, Jionglong Su,Jingxin Liu.DuAT: Dual-Aggregation Transformer Network for Medical Image Segmentation

[16]Tong, Z.,Chen,Y.,Xu,Z.,&Yu,R. (2023). Wise-iou: Bounding box regression loss with dynamic focusing mechanism. arXiv preprint arXiv:2301.10051.

[17]Liu C,Wang K,Li Q,etal.Powerful-IoU:More straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism[J].Neural Networks,2024,170:276-284.

[18]Deng-Ping Fan,Ge-Peng Ji,Tao Zhou,Geng Chen,Huazhu Fu,Jianbing Shen,and Ling Shao. Pranet:Parallel reverse attention network for polyp segmentation. In International conference on medical image computing and computer assisted intervention, pages263-273.Springer,2020.

作者简介:

杨焱磊(1998--),男,汉族,山西临汾人,研究生,研究方向:图像检测,计算机视觉。