

改进YOLOv5的安全帽佩戴检测算法

徐华^{1,2,3}, 邓在辉^{1,2}, 姚冲^{1,2}, 叶彩瑞^{1,2}

(1. 武汉纺织大学计算机与人工智能学院; 2. 湖北省服装信息化工程技术研究中心;
3. 湖北城市建设职业技术学院, 湖北武汉430200)

摘要:近年来, 安全帽佩戴检测在深度学习领域得到广泛研究, 为解决现有安全帽检测算法精度低、抗干扰能力弱、移植性较差等问题, 提出一种基于改进YOLOv5的目标检测算法。首先, 引入残差模块将深层特征信息与浅层特征信息相连, 加强网络间的信息交流; 然后结合坐标注意力机制(CA), 在不增加计算量的前提下提升模型特征提取能力; 最后优化损失函数曲线, 以提升模型回归效果。实验表明, 所提模型相较于传统YOLOv5方法检测精度提升3.6%, 能快速准确地检测安全帽, 更适合解决实际工程问题。

关键词: 安全帽检测; YOLOv5; 坐标注意力机制; 残差网络

DOI: 10.11907/rjdk.221885

开放科学(资源服务)标识码(OSID):

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2023)008-0033-09



Helmet Wearing Detection Algorithm by Improved YOLOv5

XU Hua^{1,2,3}, DENG Zaihui^{1,2}, YAO Chong^{1,2}, YE Cairui^{1,2}

(1. School of Computer Science and Artificial Intelligence, Wuhan Textile University;

2. Engineering Research Center of Hubei Province for Clothing Information;

3. Hubei Urban Construction Vocational and Technological College, Wuhan 430200, China)

Abstract: In recent years, helmet wearing detection has been widely studied in the field of deep learning. In order to solve the problems of low accuracy, weak anti-interference ability, and poor portability of existing helmet detection algorithms, an improved YOLOv5 based object detection algorithm is proposed. Firstly, the residual module is introduced to connect deep feature information with shallow feature information, enhancing information exchange between networks; Then, combined with the coordinate attention mechanism (CA), the model's feature extraction ability is improved without increasing computational complexity; Finally, optimize the loss function curve to improve the regression effect of the model. The experiment shows that the proposed model improves the detection accuracy by 3.6% compared to the traditional YOLOv5 method, and can quickly and accurately detect safety helmets, making it more suitable for solving practical engineering problems.

Key Words: helmet detection; YOLOv5; coordinate attention mechanism; ResNet

0 引言

在建筑、电力、化工等施工场所, 高空坠落、物体打击等安全事故偶有发生。为了降低或避免此类事故发生, 对从业人员头部造成伤害, 进入施工场所需依规佩戴安全帽。然而, 由于施工场所环境复杂, 人员流动性大, 从业人员安全意识匮乏及企业监管不力等因素, 导致部分从业人员在

进入施工区域时仍未能按规定佩戴安全帽, 给企业安全生产带来了隐患。现阶段, 大多数企业通过人工监督人员是否佩戴安全帽, 但所需成本高、监管区域有限、误差大、效率低, 无法满足现代行业安全管理需求。因此, 基于计算机视觉的安全帽检测方法逐渐成为企业安全管理的主要手段。

目前, 利用计算机视觉检测从业人员是否佩戴安全帽具有应用领域广、适用性强的优势, 已成为了一个典型的

收稿日期: 2022-07-29

基金项目: 国家自然科学基金项目(61170093); 武汉纺织大学基金项目(20220609)

作者简介: 徐华(1995-), 男, 武汉纺织大学计算机与人工智能学院硕士研究生, 湖北城市建设职业技术学院助教, 研究方向为计算机视觉; 邓在辉(1976-), 男, 武汉纺织大学计算机与人工智能学院副教授、硕士生导师, 研究方向为计算机视觉、网络安全、物联网; 姚冲(1997-), 男, 武汉纺织大学计算机与人工智能学院硕士研究生, 研究方向为计算机视觉; 叶彩瑞(1996-), 男, 武汉纺织大学计算机与人工智能学院硕士研究生, 研究方向为网络安全。本文通讯作者: 邓在辉。

目标检测问题,但由于安全帽特征较小,在真实作业场景中易受环境因素影响,例如阴雨天气场景灰暗、光照强曝光度高、物体遮挡等因素会导致模型识别精度降低。

为此,国内外许多学者使用机器学习方法开展相关研究。刘晓慧等^[1]通过工人面部特征与肤色相关信息进行定位,将头发与安全帽颜色进行二分类,判断工人是否佩戴安全帽。冯国臣等^[2]使用高斯模型与人体边缘特征信息相结合的方式安全进行检测。Rubaiyat等^[3]首先利用方向梯度直方图(Histogram of Oriented Gradient, HOG)寻找人的目标位置,通过头发颜色及圆形霍夫变换(Circle hough Transform, CHT)设计安全帽特征,最后进行判断。

然而,上述方法均通过滑动窗口遍历筛选得到目标区域后使用分类器进行识别,筛选方式较简洁、可靠性较差,并且采用穷举策略,庞大的计算量会导致模型检测速度下降,还需要人工设计特征,一旦检测目标不同需要人工重新提取分类特征,因此在复杂环境下模型的鲁棒性不高、可移植性较差,不适解决实际工程问题。

近年来,多层神经网络不断发展,衍生出一种针对图像分类和识别的深度学习目标检测方法,具有检测精度高、速度快的特点,逐渐替代传统目标检测方法成为行业主流。基于深度学习的目标检测算法可分为:以SSD^[4]、RetinaNet^[5]、YOLO^[6-9]为代表的单阶段(One-stage)检测算法;以R-CNN^[10]、Fast R-CNN^[11]、Faster R-CNN^[12]为代表的两阶段(Two-stage)检测算法。

基于卷积神经网络的安全帽检测方法一直是目前研究的热点,国内许多学者^[13-14]利用YOLO、R-CNN和SSD等系列算法在安全帽检测上开展了广泛研究,但由于施工场所环境较为复杂,施工区域存在阴影、部分区域存在高光现象、安全帽颜色受噪声干扰造成失真等因素会影响模型检测精度、降低模型适用性。

为此,本文在不减少模型输入的前提下优化YOLOv5网络结构,提出一种改进的YOLOv5安全帽检测算法。实验表明,该模型相较于现有主流算法检测效果更优、网络精度更高,显著提升了模型在复杂施工场景下的检测性能。

1 相关工作

随着计算机硬件性能不断提高,许多基于深度学习的目标检测算法得以发展。YOLO系列目标检测算法具有网络结构简单、精度高、速度快、鲁棒性强等优点,得到了众多学者的广泛研究和运用,但针对安全帽等小目标检测时模型的检测精度较低、速度慢。为此,一些学者提出了一些改进方法。Zhang等^[15]引入特征金字塔结构提出一种基于YOLOv2的改进算法提升了模型的检测速度,但精度较低。许凯等^[16]以YOLOv3为基础增加特征图后使用K-means聚类算法缓解正负样本不均衡的问题,但网络结构

复杂会导致检测速度降低。金雨芳等^[17]提出一种基于YOLOv4的改进算法,通过增加128×128特征图以缩小输出目标特征,并改进特征融合模块,结合Head分类器与多层次的特征得到了较好的分类检测效果,但当目标被遮挡或在环境复杂场景下算法的检测效果欠佳。赵红成等^[18]提出基于YOLOv5的YOLO-S模型,将MobileNetV2作为YOLOv5的主干,并引入缩放因子与知识蒸馏相结合的方法压缩模型,虽然在一定程度上提升了模型的检测速度,但当目标紧密排布或被遮挡时检测效果不佳。赵睿^[19]在YOLOv5检测算法的基础上采用DenseBlock模块替代原模型主干网络(Backbone)中的Focus切片操作,并在Neck层中加入SE-Net注意力模块以提升模型获取特征的能力,虽然检测效果较好,但其权重分配会增加模型参数量导致检测速度下降,且在灰暗场景下的检测效果不佳。

虽然上述方法对YOLO系列算法进行了改进,但在实际施工场景下对近似目标、密集目标及灰暗目标的检测效果依然不够理想,且参数多、计算量大,无法满足实时检测的要求。

为此,本文提出一种改进的YOLOv5目标检测算法。首先减少两层网络,通过残差思想添加卷积单元,将原始输入添加残差以减少参数量;然后增加CA注意力机制以提升模型对目标区域的关注程度;最后使用CIoU_loss替代GIoU_loss以提升预测框的回归效果。

2 改进YOLOv5网络

2.1 YOLOv5网络

2020年,Ult公司在YOLO基础上不断创新优化,衍生出基于Python的轻量级检测模型——YOLOv5目标检测算法。根据不同模型权重、深度和特征图宽度可分为YOLOv5、YOLOv5m、YOLOv5l、YOLOv5x共4个版本。由于YOLOv5模型在COCO、PASCAL VOC数据集上的检测速度、精度最均衡,因此本文采用YOLOv5s作为检测模型,并在其基础上进行改进。YOLOv5模型的网络结构分为Input层,Backbone层,Neck模块及输出层4个部分,如图1所示。

由图1可见,Input层由Mosaic-4数据增强方式、自适应Anchor及自适应缩放图片3部分组成。其中,Mascio-4数据增强将4张图片经过随机缩放、裁剪,再随机拼接成一张完成的图片作为模型输入,如此既可丰富背景又能增加小目标数量,还能提升模型的健壮性;自适应Anchor通过计算预测框与真实框的差值,通过反向更新、不断迭代获取最优锚框。

Backbone层采用CSPDarknet53网络,网络主干由Focus、C3、Conv、SPP等4个模块组成。其中,Focus模块主要进行切片操作得到下采样特征图(见图2),以减少层数、参数FLOPS(每秒浮点数运算)、CUDA内存,增加前向和后向

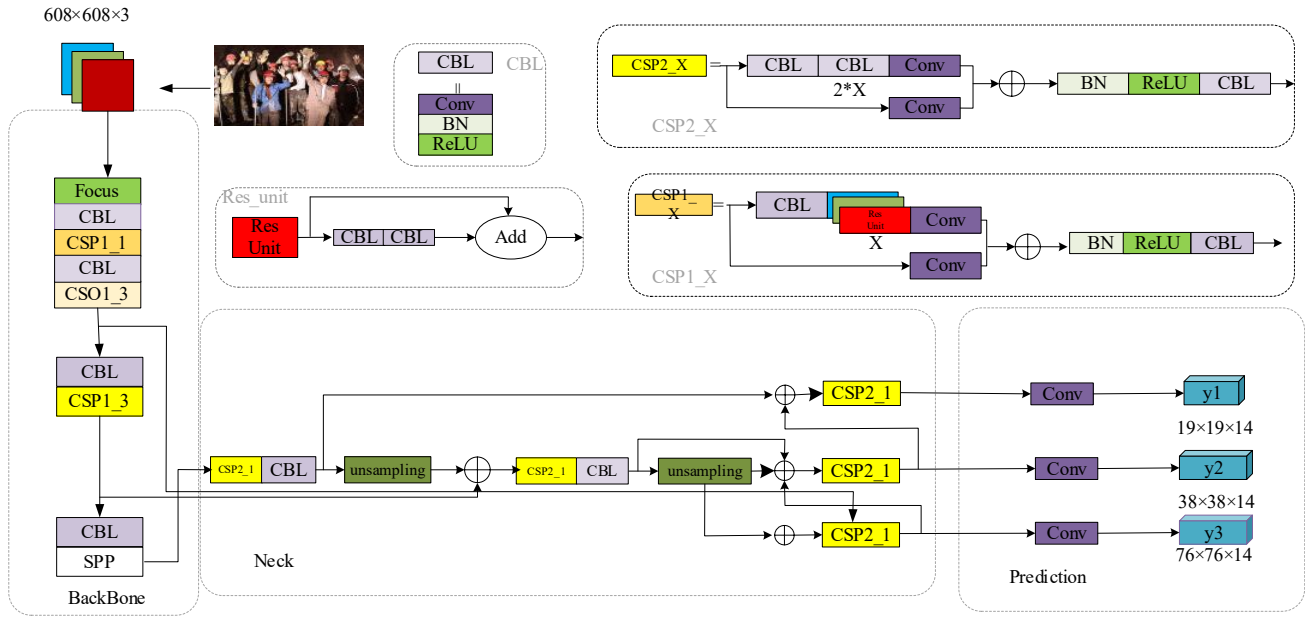


Fig. 1 YOLOv5 structure

图 1 YOLOv5 结构

的传播速度;Conv 为由 Conv2d+BatchNorm2d+SILU 激活函数组成的标准卷积模块,以进一步提升模型精度,优化收敛效果;C3 模块为基于跨阶层部分(CSP)网络的残差块,包含 3 个卷积模块,主要作用为增强特征提取能力,减少参数、内存;SPP 为空间金字塔池化,通过最大池化层(Global Max Pooling, GMP)实现不同感受野间特征的输出,极大降低了重复提取图像特征的概率和计算成本。




Fig. 2 Focus slice operation

图 2 Focus 切片操作

Neck 层进一步利用了主干网络提取的特征,对 Backbone 不同阶段提取的特征进行重新处理并合理使用,采用特征金字塔 (Feature Pyramid Networks, FPN) 框架和路径增强网络 (Path Aggregation Network, PAN) 框架相结合的结构。其中,FPN 自顶向下传递强语义特征,PAN 自底向上传递强定位特征,两者相结合以进一步提升模型特征融合能力。此外,多重特征融合实现了网络对 3 个特征层的全提取,提升了模型对密集目标的检测性能,如图 3 所示。

输出层采用 GIoU_loss 作为边界框 (Bounding box) 的损失函数,相较于 IoU_loss 增加了非重叠区域的影响,在两个矩形框不相交时可进行学习训练。在目标检测推理过程中采用非极大值抑制 (Non Maximum Suppression, NMS) 方式筛选冗余的候选框,以提升模型检测性能。

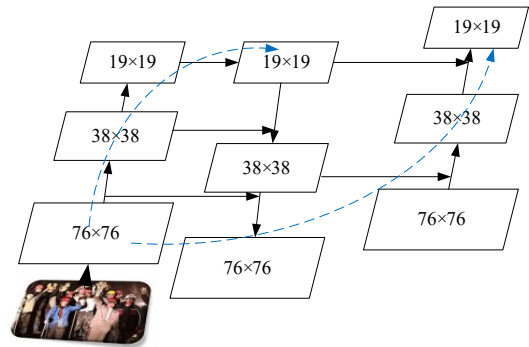


Fig. 3 FPN + PAN structure

图 3 FPN+PAN 结构

2.2 改进 YOLOv5 网络方法

为了在不改变模型输入的前提下,提升模型对安全帽等小尺寸目标检测的精度,本文对 YOLOv5 结构进行改进,网络结构如图 4 所示。首先,引入残差结构将经过上采样的深层特征信息与浅层特征信息相连,加强网络之间的信息交流;然后,与 CA 注意力机制形成注意力残差单元,提升网络提取特征能力;最后,改进损失函数以提升模型回归效果。

2.2.1 残差模块

在深度学习领域,深层网络结构通常能取得更好的分类效果,但随着卷积神经网络深度加深会产生梯度爆炸、特征消失等一系列问题,且在检测小目标时深层网络包含的小尺寸目标的有效特征信息较少,将影响模型检测精度。因此,本文在输出端的卷积间引入跳跃连接结构的残差模块,将当前输出直接传递给下一层网络,并将下层网络梯度直接传给上层网络,实现网络间的信息传递,以提升深层特征检测能力,缓解因网络层数增加所带来的梯度消失问题。具体核心思想是将回归函数 $M(x)$ 转化为 $F(x)$

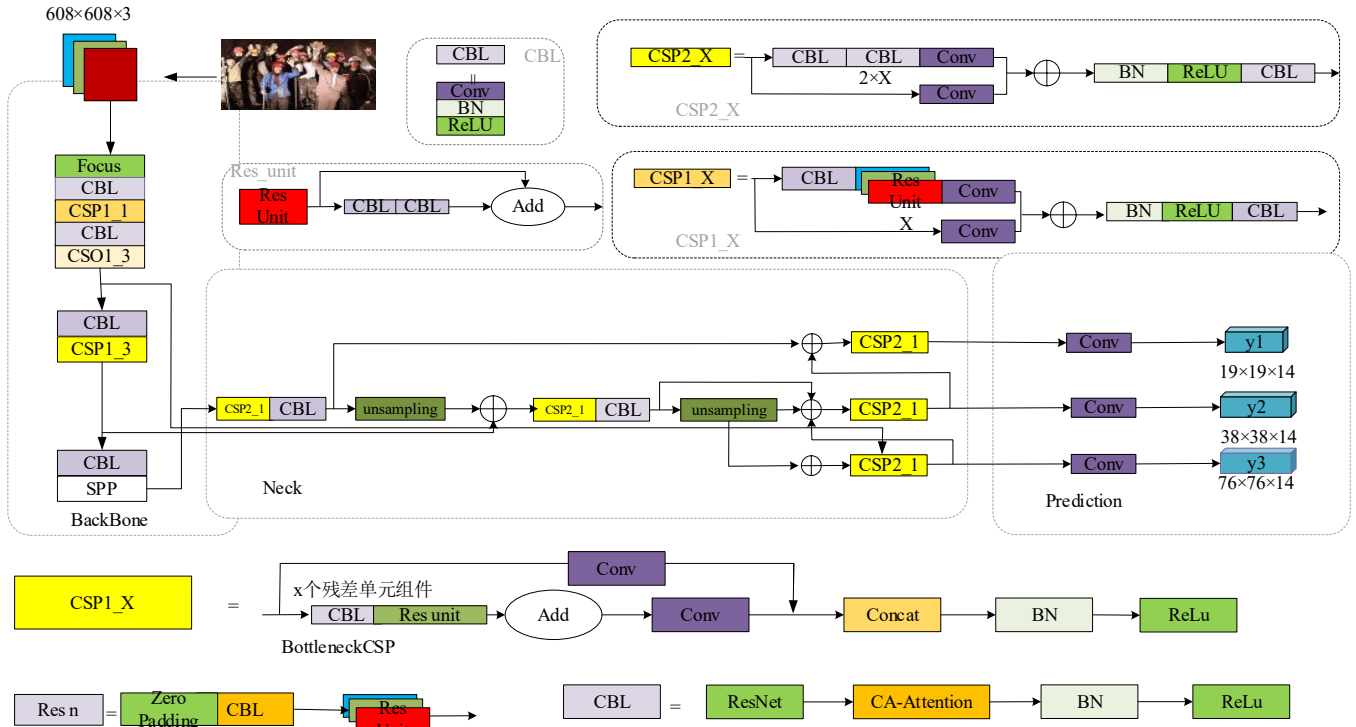


Fig. 4 Improved YOLOv5 structure

图4 改进的YOLOv5结构

+x, 如图5所示。




Fig. 5 Residual unit structure

图5 残差单元结构

由图5可见,将每个残差单元输入的特征层表示为 x , 经过卷积层学习到的特征表示为 $M(x)$, 即残差表示为 $F(x) = M(x) - x$ 。残差网络可使深层网络获取浅层网络的相关特征信息,以提升模型检测性能。浅层单元也可获取深层单元的特征表达式,计算公式如式(1)–式(3)所示。

$$H_i = m(x_i) + F(x_i, W_i) \quad (1)$$

$$x_{i+1} = f(H_i) \quad (2)$$

$$x_i = x_i + \sum_{n=i}^{l-1} F(x_i, W_i) \quad (3)$$

其中, x_i 为残差单元的输入, H_i 为残差单元的输出, W_i 为残差中卷积单元, f 为激活函数 Relu, $F(x)$ 为目标映射, x_i 为浅层单元的特征。

2.2.2 CA 注意力机制

由于安全帽等小尺寸目标在监控视频中所占比例较小、像素少,易受光照等背景因素影响。传统 YOLOv5 模

型在采样时并未考虑通道和位置信息对检测性能造成的影响,也并未针对性加强特征学习,导致部分有效特征被丢弃,造成了特征浪费。为此,本文引入注意力机制(Coordinate Attention, CA),在不增加计算量的前提下获取跨通道信息、方向感知及位置信息,辅助模型定位目标区域来扩大感受野。CA 模块主要由坐标信息嵌入(Coordinate information embedding)和坐标注意力生成(Coordinate attention generation)模块组成,能提升模型的特征提取能力,从而提升检测密集目标或灰暗目标的准确率,具体结构如图6所示。

(1)坐标信息嵌入模块。CA 注意力将全局池化分为两个一维特征并对其进行编码,以获得精确位置信息的空间长距离依赖关系。对输入维度为 $C \times W \times H$ 的特征图 X , 首先使用 $(H, 1)$ 、 $(1, W)$ 尺寸的一维池化核分别沿水平、竖直方向对每个通道进行编码,即高度为 h 第 c 个通道与宽度为 w 第 c 个通道的输出。具体计算方式如式(4)、式(5)所示。

$$Z_c^h = \frac{1}{w} \sum_{0 \leq i \leq w} X_c(h, i) \quad (4)$$

$$Z_c^w(W) = \frac{1}{H} \sum_{0 \leq j \leq w} X_c(j, w) \quad (5)$$

根据式(4)、式(5),沿着水平、竖直空间方向集合特征,级联生成方向感知注意力特征 Z^h 、 Z^w ,以便模型快速、准确地锁定目标。

(2)坐标注意力生成模块。将坐标信息嵌入模块级联得到方向特征 Z^h 、 Z^w ,使用 1×1 的共享卷积进行变换计算 F_1 ,得到空间信息在水平、垂直方向的中间特征图 f ,如式

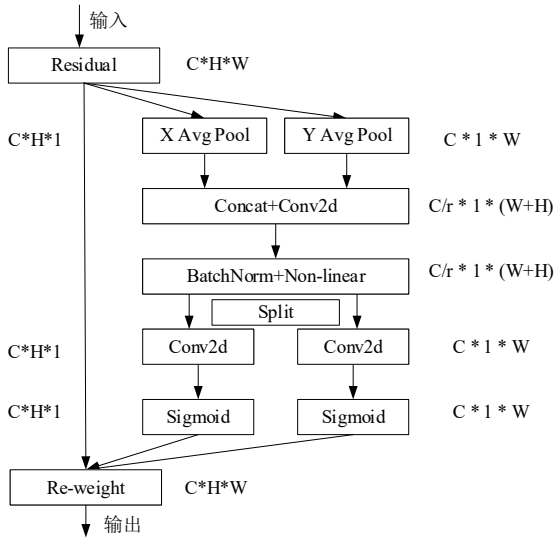


Fig. 6 CA module structure
图6 CA 模块结构

(6)所示。

$$f = \delta(F_1([Z^c, Z^w])) \quad f \in R^{C/r*(H+W)} \quad (6)$$

式中, r 为下采样比例, δ 为激活函数 Sigmoid, 进行归一化操作时限制权重处于 $[0, 1]$, $[Z^c, Z^w]$ 为在水平、垂直方向的级联操作。

然后, 将中间特征图 f 沿空间维度分解得到 f^h, f^w 两个单独的张量, 再利用一维卷积 F_h, F_w 变换空间维度分量 f^h, f^w , 使通道数与输入 X 通道数保持一致。

$$g^h = \sigma(F_h(f^h)) \quad (7)$$

$$g^w = \sigma(F_w(f^w)) \quad (8)$$

最后, 扩充 g^h, g^w 得到目标区域的相关权重, 并输出结果。

$$y_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (9)$$

(3)CA 坐标注意力是一种新颖的注意力机制, 既能在不增加额外计算开销的基础上使模型关注通道信息, 又能提升模型对空间位置坐标信息的关注度。本文将 CA 注意力机制加入 Backbone 网络, 与残差模块组合成残差模块单元以增强模型特征提取能力, 并进行针对性的特征学习以减少漏检等情况发生, 具体操作如图 7 所示。

2.2.3 损失函数

YOLOv5 模型损失函数的由置信度损失 (Objectness Score)、分类损失 (Class Probability Score) 和两个矩形框 (目标框和预测框) 之间的位置损失 (Bounding Box Regression Score) 3 个部分组成。首先, 采用二进制交叉熵 (BCE) 和 Logits 损失函数计算置信度与分类损失; 然后计算两个矩形的最小外接面积; 最后计算不属于两个框的区域占整个区域的比重。具体计算公式如 (10)、式 (11) 所示。

$$GIoU = IoU - \frac{|A^c - U|}{|A^c|} \quad (10)$$

$$L_{GIoU} = 1 - GIoU \quad (11)$$

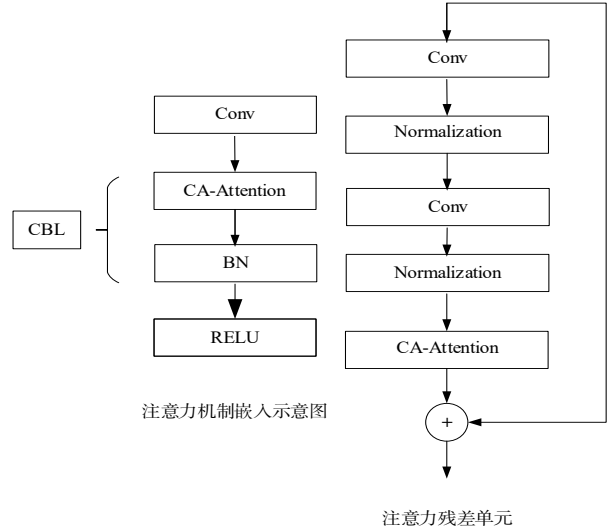


Fig. 7 Attention mechanism
图7 注意力机制

其中, A^c 为两个矩形的最小外接面积。

原模型采用 GIoU_loss 作为边界框的损失函数, 虽然 GIoU_loss 解决了损失函数的梯度问题, 但当 IoU 与 GIoU 数值相等时损失函数值也一致, 此时将无法较好的衡量两个矩形间的相对位置关系。此外, 预测框在水平或垂直方向上优化较为困难, 且当预测框与真实框为包含关系时 GIoU 便无法衡量其相对位置, 将导致 GIoU_loss 不稳定且收敛慢, 如图 8 所示 (预测框在目标框内部)。



Fig. 8 Problems of GIoU
图8 GIoU 存在的问题

为此, 本文使用 CIoU_loss 替代 GIoU_loss 作为本文边界框的损失函数。CIoU 不仅计算了预测框与真实框之间交集的面积, 还将预测框中心点到真实框中心点间的绝对值视为两个矩形框的距离。当预测框在真实框内时, CIoU 既能计算预测框与目标框的间距, 还可计算边界框中心点之间的间距, 并考虑了边界框宽与高之间比值的相关尺度信息, 以提升预测框的回归效果。具体计算公式如式 (12)、式 (13) 所示。

$$L_{DIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} \quad (12)$$

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \partial v \quad (13)$$

其中, ρ^2 代表预测框与真实框中心点距离的平方, C^2 代表预测框与真实框最小凸形的对角线长度平方, b 为预测框中心, b^{gt} 为真实框的中心, α 为权衡参数, v 为预测框与

真实框之间长宽比的一致性, $\frac{w^{gt}}{h^{gt}}$ 为真实框宽与高的比值, $\frac{w}{h}$ 为预测框宽与高的比值, 计算公式如式(14)、式(15)所示。

$$\alpha = \frac{v}{(1 - IoU) + v} \tag{14}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \tag{15}$$

由上式可知, 使用 CIoU_loss 替代 GIoU_loss, 当两个矩形框宽高比完全重叠时, 模型将重点考虑预测框与真实框之间的差异, 以此提升预测框的回归效果。

3 实验结果与分析

3.1 数据集与实验环境

本次实验操作系统为 Windows10, CPU 为 AMD Ryzen 7 5800H with Radeon Graphics 3.20 GHz, GPU 为 GeForce RTX 3050, Python 3.6、CUDA 11.2, 模型训练和测试框架均基于 PyTorch。

由于目前现有数据集无法满足本文实验要求, 因此通过施工现场特定点位监控视频分帧、施工现场拍摄、网络爬取等方式自主收集图像, 将 VOC 格式转为 YOLO 格式, 文件名与图像名一致, 并采用 labelImg 进行手动标注(见图9), 共收集到不同施工场景、分辨率、灰度的 3 000 张图像作为数据集, 基本情况如图 10 所示。其中, anquanmao 为佩戴安全帽, head 为未佩戴安全帽, 图 10(a) 为佩戴安全帽样本数量与未佩戴安全帽的样本数量, 图 10(b) 为数据集中目标大小的基本情况, 深色区域集中小目标的数量较多, 图 10(c) 为类别位置分布信息。



Fig. 9 Labeling of safety helmet wearing situations
图9 安全帽佩戴情况标注

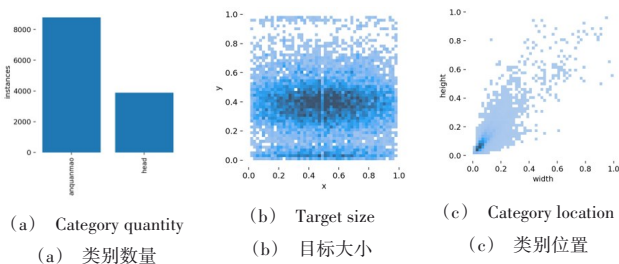


Fig. 10 Basic information of the dataset
图10 数据集基本情况

3.2 评价指标

本文通过采用准确率(Accuracy)、召回率(Recall), 平均精度(Mean Average Precision, mAP)作为评价指标, 以验证改进模型的有效性。其中, 准确率为预测正确结果占总样本的比例; 召回率为预测样本中实际样本数与预测样本数的比值; 平均精度为在不同召回率下取得的平均值, 求解 AP 的均值即可得到。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{16}$$


$$Recall = \frac{TP}{TP + FN} \tag{17}$$

$$AP = \sum_{i=1}^n p(i) \Delta r(i) = \int_0^1 p(r) dr \tag{18}$$

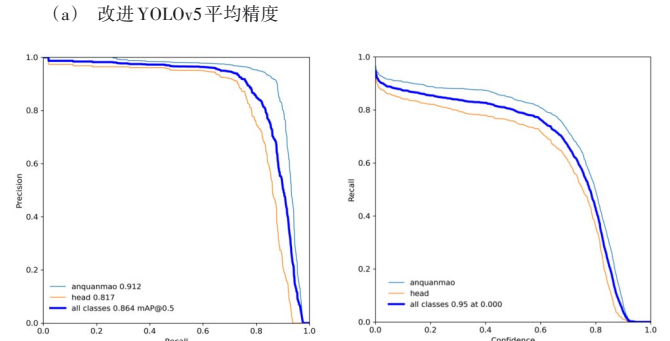
其中, TP、TN 分别指正、负样本预测值与实际样本类型相同, FP 代表将负样本预测为正, FN 代表将正样本预测为负, n 为类别, N 为总类别数, AP 为 P-R 曲线围起来的面积。

3.3 实验结果

将改进后的模型与原模型在相同环境下进行训练, 改进前后 YOLOv5 模型在自制数据集上训练的平均精度和召回率曲线如图 11 所示。



(a) Average accuracy of improved YOLOv5
(b) 改进 YOLOv5 召回率



(c) YOLOv5 平均精度
(d) YOLOv5 召回率

Fig. 11 Training results of improved YOLOv5 and YOLOv5
图11 改进 YOLOv5 与 YOLOv5 的训练结果

此外, 为了更直观体现改进前后算法在检测性能方面的差距, 将算法在自制数据集上进行检测, 部分检测效果如图 12 所示。其中, 佩戴安全帽的施工人员上方出现“anquanmao”, 未佩戴安全帽的施工人员上方出现“head”。

图 12(a)、图 12(b)为强光照施工场景,由此可见原模型将图 12(a)中木头圆柱误检为未佩戴安全帽的施工作业人员,而改进后的模型能全部正确检出;原模型将图 12(b)中施工人员腰间的黄色工具包被误检为佩戴安全帽的施工作业人员,改进后的模型能全部正确检出。图 12(c)为密集场景,原模型漏检了 3 个在钢筋附近佩戴安全帽的施工作业人员,改进后的模型能全部正确检出。图 12(d)为不同尺寸目标检测,原模型漏检了远景尺寸较小的目标,改进后的模型能全部正确检出。图 12(e)为灰暗场景,原模型将佩戴安全帽的作业人员误检成未佩戴安全帽的工作人员且漏检了后排两个佩戴安全帽的作业人员,改进后的模型能全部正确检出。

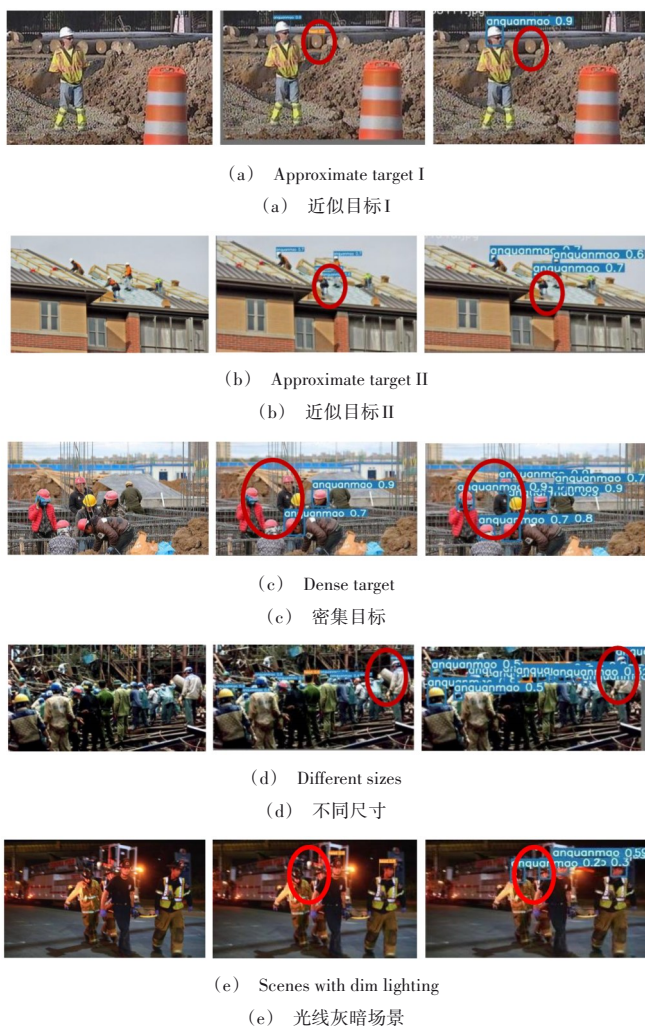


Fig. 12 Comparison of partial model detection results in different scenarios

图 12 不同场景下模型部分检测结果比较

综上所述,在不同场景、距离条件下,改进后的 YOLOv5 模型检测安全帽的准确率更优。

3.4 消融实验

为了验证各改进模块的优化性能,本文还设置了消融实验,结果如表 1 所示。其中,改进 1 在主干网络中引入残差网络;改进 2 在主干网络加入坐标注意力机制;改进 3 对

损失函数进行改进。

Table 1 Results of ablation experiment

表 1 消融实验结果

方法	残差网络	CA	损失函数	mAP@0.5/%	ms
YOLOv5				86.4	25
改进 1	√			87.1	23
改进 2		√		88.6	26
改进 3			√	86.7	23
改进 YOLOv5	√	√	√	90.0	28

由表 1 可知,改进 1 精度相较于 YOLOv5 模型提升 0.7%,时间缩短 2ms,主要因为深层网络能获取浅层网络的特征信息,既减少了计算量还提升了模型检测精度;改进 2 平均精度相较于 YOLOv5 模型提升 2.2%,时间缩短 1ms,主要因为 YOLOv5 模型提取特征的能力较弱,易发生漏检,添加 CA 模块后模型的特征提取能力得到显著提升;改进 3 相较于 YOLOv5 模型时间缩短 2ms,主要因为 CIoU 考虑预测框与真实框间中心点间的距离、长宽比及重叠区域,有利于模型训练,提升了模型的检测速度和精度。

图 13 为训练的 box_loss 曲线图(彩图扫 OSID 可见,下同),蓝色曲线代表原模型损失函数值,褐色曲线代表改进后模型的损失函数值。由此可见,改进后模型相较于原模型收敛速度更快,损失值更小,证明了该模型的有效性和优势。图 14 为平均精度 mAP 比较曲线(阈值为 0.5),褐色曲线为改进后 YOLOv5 模型,蓝色曲线为原 YOLOv5 模型,随着训练次数增加曲线逐渐趋于平稳,平均精度相较于原模型提升 3.6%。

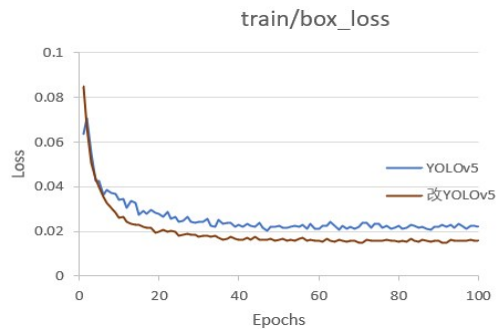


Fig. 13 Loss descent curve

图 13 Loss 下降曲线




Fig. 14 mAP curve

图 14 mAP 曲线

3.5 目标检测算法比较

将本文算法与SSD、YOLOv3和Faster R-CNN等主流目标检测算法在相同的实验环境及配置下,采用相同数据集分别训练100次,实验结果如表2所示。由此可知,本文算法相较于其他主流算法检测性能更优。

3.6 改进安全帽检测算法比较

将本文算法与文献[15-19]所提安全帽佩戴检测算法的改进部分进行比较,实验结果如表3所示。由此可知,本文算法的mAP@0.5%、mAP均优于其他改进算法。

Table 2 Performance comparison of mainstream target detection models

表2 主流目标检测模型性能比较

模型	主干网络	mAP@0.5%	模型大小
SSD	Vgg16	75.7	188
Faster R-CNN	Resnet10	64.3	166.3
YOLOv3	Darknet53	82.1	247
YOLOv3-SPP	Darknet53	83.7	247.6
YOLOv4	CSPDarknet53	85.2	251
YOLOv5	CSPDarknet53	86.4	15.3
本文方法	CSPDarknet53	90.0	16.0

Table 3 Comparison of different improved helmet detection algorithms

表3 不同改进的安全帽检测算法比较

改进部分	mAP@0.5%	mAP
k-means聚类	83.26	53.17
k-means++聚类	84.38	56.42
增加自注意力机制	86.12	55.79
增加特征图	86.93	55.32
SE-Net注意力机制	87.87	58.03
本文方法	90.0	60.12

3.7 小目标检测算法比较

将本文算法与文献[20-23]所提小目标检测算法进行比较,实验结果如表4所示。由此可知,本文算法在精度提升及速度方面具有一定优势。

Table 4 Comparison of different small target detection algorithms

表4 不同其他小目标检测算法比较

模型	精度提升/%	模型大小	速度/FPS
YOLOv5-C ^[20]	1.3	14.8	75
YOLOv5-dress ^[21]	1.6	17	70
YOLOv5-K ^[22]	2.6	19	54
YOLOv5-QFBC ^[23]	2.1	21	69
本文方法	3.6	16	73

4 结语

本文针对目前安全帽检测算法在真实施工场景检测中,对不同尺度、密集及灰暗目标存在漏检、误检现象,检

测精度较低的问题,提出一种改进YOLOv5的安全帽检测算法。该算法在主干网络引入残差网络、CA注意力机制、损失函数等提升模型对不同尺度、密集目标的检测能力,进而增强模型的鲁棒性。

在自制数据集上的实验结果表明,改进YOLOv5算法的检测性能相较于传统YOLOv5算法更优,能满足复杂施工场景下对安全帽检测精度的要求,证明了所提算法的有效性和优越性。

参考文献:

- [1] LIU X H, YE X N. Application of skin color detection and Hu moment in helmet recognition [J]. Journal of East China University of Science and Technology (Natural Science Edition), 2014, 40(3): 365-370.
刘晓慧,叶西宁. 肤色检测和Hu矩在安全帽识别中的应用[J]. 华东理工大学学报(自然科学版), 2014, 40(3): 365-370.
- [2] FENG G C, CHEN Y Y, CHEN N. Research on automatic helmet recognition technology based on machine vision [J]. Mechanical Design and Manufacturing Engineering, 2015, 44(10): 39-42.
冯国臣,陈艳艳,陈宁. 基于机器视觉的安全帽自动识别技术研究[J]. 机械设计与制造工程, 2015, 44(10): 39-42.
- [3] RUBAIYAT A H, TOMA T, KALANTARI-KHANDANI M, et al. Automatic detection of helmet uses for construction safety [C]// Proceedings of the International Conference on Web Intelligence Workshops, 2016: 135-142.
- [4] LIU W, ANGUEIOV D, ERHAN D, et al. SSD: single shot multibook detector [C]// Proceedings of the European Conference on Computer Vision, 2016: 21-37.
- [5] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]// Proceedings of the 2017 IEEE International Conference on Computer Vision, 2017: 2999-3007.
- [6] REDOM J, DIVALA S, GIRSHICK R, et al. You only look once: unified, real-time object [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [7] REDOM J, FARHADI A. YOLO9000: better, faster, stronger [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [8] REDMON J, FARHADI A. YOLOv3: an incremental improvement [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 89-95.
- [9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [C]// Seattle: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020.
- [10] GIRSHICK R, DONA J, DARRLELL T, et al. Rich feature hierarchies for object detection and segmentation [C]// Proceedings of the 2014 IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014: 580-587.
- [11] GIRSHICK R. Fast R-CNN [C]// Proceedings of the 2015 IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Information Intelligence, 2017, 39(6): 1137-1149.

- [13] GUAN Y Q, HOU Q. A deep learning algorithm for helmet detection scene [J]. *Electronics World*, 2021(22):86-88.
关雅琪,侯群.一种用于安全帽检测场景的深度学习算法[J].*电子世界*, 2021(22):86-88.
- [14] LIANG S C, XU Z M, SONG Y. Application of YoloV3 algorithm in helmet detection [J]. *Intelligent Computer and Application*, 2020, 10(9): 1-5.
梁思成,徐志明,宋毅.YoloV3算法在安全帽检测中的应用[J].*智能计算机与应用*, 2020, 10(9):1-5.
- [15] ZHANG M, LI J, DING R L, et al. Remote sensing image object detection technology based on improved YOLOv2 algorithm [J]. *Computer Science*, 2020, 47(S1): 176-180.
张曼,李杰,丁容莉,等.基于改进YOLOv2算法的遥感图像目标检测技术研究[J].*计算机科学*, 2020, 47(S1): 176-180.
- [16] XU K, DENG C. Helmet wearing recognition algorithm based on improved YOLOv3 [J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 300-307.
许凯,邓超.基于改进YOLOv3的安全帽佩戴识别算法[J].*激光与光电子学进展*, 2021, 58(6): 300-307.
- [17] JIN Y F, WU X, DONG H, et al. Helmet detection algorithm based on improved YOLOv4 [J]. *Computer Science*, 2021, 48(11): 268-275.
金雨芳,吴祥,董辉,等.基于改进YOLOv4的安全帽检测算法[J].*计算机科学*, 2021, 48(11): 268-275.
- [18] ZHAO H C, TIAN X X, YANG Z S, et al. YOLO-S: a new lightweight helmet wearing detection model [J]. *Journal of East China Normal University (Natural Science Edition)*, 2021(5): 134-145.
赵红成,田秀霞,杨泽森,等.YOLO-S:一种新型轻量的安全帽佩戴检测模型[J].*华东师范大学学报(自然科学版)*, 2021(5):134-145.
- [19] ZHAO R, LIU H, LIU P L, et al. Helmet detection algorithm based on improved YOLOv5 [J/OL]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021-11-23. https://kns.cnki.net/kcms2/article/abstract?v=3uoqIhG8C45S0n9fL2suRadTyEVl2pW9UrhTDCdPD65oE-IcCnq5ld8uAHQtq_MvLpV9JCNr2gOqoJb4LSOTJp6uXNfPwPdop&uniplatform=NZKPT.
赵睿,刘辉,刘沛霖,等.基于改进YOLOv5的安全帽检测算法[J/OL].*北京航空航天大学学报*, 2021-11-23. http://www.jos.org.cn/jos/ch/journal_id=jos.
- [20] QIU J H, BEI S T, YIN M F, et al. Gear surface defect detection based on improved YOLOv5s [J]. *Modern Manufacturing Engineering*, 2022(3): 104-113.
仇娇慧,贝绍铁,尹明锋,等.基于改进YOLOv5s的齿轮表面缺陷检测[J].*现代制造工程*, 2022(3): 104-113.
- [21] TIAN F, JIA H P, LIU F, et al. Improving the detection of small targets of safety clothing on oil field operation site with YOLOv5 [J]. *Computer Systems & Applications*, 2022, 31(3): 159-168.
田枫,贾早鹏,刘芳,等.改进YOLOv5的油田作业现场安全着装小目标检测[J].*计算机系统应用*, 2022, 31(3): 159-168.
- [22] ZHANG H Q, BAN Y M, GUO L L, et al. Ship detection method based on YOLOv5 remote sensing image [J]. *Electronic Measurement Technology*, 2021, 44(8): 87-92.
张宏群,班勇苗,郭玲玲,等.基于YOLOv5的遥感图像舰船的检测方法[J].*电子测量技术*, 2021, 44(8): 87-92.
- [23] WANG P F, HUANG H M, WANG M Q, et al. Complex road target detection algorithm based on improved YOLOv5 [J]. *Computer Engineering and Application*, 2022, 58(17): 81-92.
王鹏飞,黄汉明,王梦琪,等.基于改进YOLOv5的复杂道路目标检测算法[J].*计算机工程与应用*, 2022, 58(17): 81-92.

(责任编辑:刘嘉文)