

DOI:10.19651/j.cnki.emt.2416143

改进 YOLOv8 的轻量化安全帽佩戴检测算法^{*}

张国鹏^{1,2} 周金治^{1,2} 马光岑^{1,2} 贺浩洋^{1,2}

(1. 西南科技大学信息学院 绵阳 621000; 2. 特殊环境机器人技术四川省重点实验室 绵阳 621000)

摘要: 针对安全帽佩戴检测模型大、运算复杂、对运算平台资源要求高的问题,提出了基于 YOLOv8 改进的轻量化安全帽佩戴检测算法 YOLOv8-MBS。首先,利用 MobileNetv3 与 SPPF 共同组成新的轻量级主干层,降低了算法的参数数量和计算量。其次,使用加权双向金字塔增强了算法的特征提取与特征表达能力,降低了误检率。最后,嵌入 SimAM 无参数注意力机制,提升网络对位置信息与安全帽特征的关联度,但不增加额外计算负担。实验结果表明,对比原始网络 YOLOv8n,改进后的 YOLOv8-MBS 在保持较高的检测精度的同时,运算量降低 35.96%,参数量降低 25.63%,模型大小降低 23.22%,帧率提高 12.52 fps。模型的轻量化降低了部署成本,为嵌入式部署及大规模应用提供了理论支持。

关键词: 安全帽佩戴检测;轻量化;注意力机制;改进 YOLOv8;BiFPN

中图分类号: TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

Lightweight safety helmet wearing detection algorithm of improved YOLOv8

Zhang Guopeng^{1,2} Zhou Jinzhi^{1,2} Ma Guangcen^{1,2} He Haoyang^{1,2}

(1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China;

2. Sichuan Provincial Key Laboratory of Robot Technology Used for Special Environment, Mianyang 621000, China)

Abstract: In response to the issues of large model size, complex computations, and high resource demands on computational platforms in safety helmet detection models, a lightweight safety helmet detection algorithm called YOLOv8-MBS, based on an improvement of YOLOv8, is proposed. A new lightweight backbone module was first formed by combining MobileNetv3 with SPPF, reducing the algorithm's parameter and computational load. Moreover, the algorithm's feature extraction and representation capabilities are enhanced using a weighted bidirectional feature pyramid network, which also reduces the false detection rate. Finally, the SimAM module is incorporated to improve the network's correlation between positional information and safety helmet features without increasing the computational burden. Experimental results show that compared to the original YOLOv8n network, the improved YOLOv8-MBS maintains high detection accuracy while reducing computation by 35.96%, the number of parameters by 25.63%, and model size by 23.22%, and increasing the frame rate by 12.52 fps. The lightweight nature of the model reduces deployment costs and provides theoretical support for embedded deployment and large-scale applications.

Keywords: safety helmet wearing detection;lightweight;attentional mechanism;improved YOLOv8;BiFPN

0 引言

佩戴安全帽能够有效防范或降低高空坠物对头部的伤害,是保障施工人员人身安全的一项重要措施。现实中安全帽佩戴检测通过人工督促的方式,存在安全漏洞大、成本高及效果差等问题。因此,通过图像进行安全帽佩戴检测具有现实意义^[1]。

传统图像检测依靠手工构造被检测对象的特征^[2-4],这些方法需要提取大量的特征样本才能实现对安全帽佩戴的有效识别,耗费大量的时间成本与人力成本,同时算法鲁棒性差,难以实际应用。自从基于区域的卷积神经网络(region-based convolutional neural network, RCNN)^[5]提出后,因其检测效果远优于传统图像检测,基于深度学习的检测方法逐渐取代传统图像检测方法成为主流检测方法。

收稿日期:2024-05-30

*基金项目:国家自然科学基金(61771411)项目资助

随着 YOLOv1^[6] (you only look once, version 1) 为代表的单阶段目标检测^[7]方法提出, YOLO 系列在目标检测广泛应用, 朱栋等^[8]将其用于太阳能电池板的缺陷检测研究。

近年来,许多研究人员综合安全帽检测特点及检测环境对安全帽佩戴检测算法进行优化。李振华等^[9]针对复杂环境下密集、遮挡安全帽检测存在漏检的问题, 在 YOLOv3 框架基础上引入多尺度注意力机制及优化 K-means 聚类算法, 提升了模型检测精度;王晓龙等^[10]构建一种基于多阶段网络训练策略的模型 YOLOX-m, 使用残差化重参视觉几何组与快速空间金字塔池化相结合, 提高检测精度和推理速度;左明成等^[11]改进单步多框目标检测 (single shot multibox detector, SSD) 算法, 同时结合多人姿态估计算法来判断安全帽的佩戴情况, 大幅度提高了提高煤矿井下作业场景的工人安全帽佩戴识别准确度, 其准确率达到了 91.9%, 但其推理速度较慢。

以上的安全帽佩戴检测方法主要集中研究检测精度, 但这导致模型复杂程度和计算量不断增加。复杂模型难以在计算资源有限的设备上流畅运行, 限制了实际应用。随着边缘计算的发展, 将模型部署在嵌入式平台上能降低成本并易于扩展。然而, 由于嵌入式平台资源有限, 需对网络进行轻量化设计。对此, 刘昶成等^[12]在 YOLOv5 的基础上引入可深度分离卷积 GhostConv, 降低了网络的计算量和参数量, 其优化后的模型大小为 14.1 MB。王媛彬^[13]用 ShuffleNetV2 替换原始 YOLOv5s 中的普通卷积 Conv, 从而降低模型参数量, 优化后的模型参数量为 6.74 M。上述

研究已对模型进行了轻量化改进, 具备部署至嵌入式平台的前提。但模型大小对于低端嵌入式平台仍然比较大, 为推广实际应用, 应继续减小对嵌入式平台资源的要求, 以降低应用成本。

因此本文提出了一种在保证检测精度的前提下, 极具轻量化的算法 YOLOv8-MBS, 使能在低性能的嵌入式平台上部署, 降低部署成本。首先采用 MobileNetv3 中的到残差结构对主干层进行轻量化设计, 大幅度的降低计算量;其次, 对 Neck 层的特征融合模块进行优化, 增强了特征融合能力, 以提高算法检测精度;最后在 head 层中加入轻量级注意力模块 (simple attention module, SimAM), 使网络抑制图片中不重要信息, 集中处理重要信息, 提高模型的鲁棒性和泛化能力。在安全帽佩戴检测数据集 (safety helmet wearing dataset, SHWD) 中进行实验, 结果表明改进后的算法对比原始 YOLOv8n 算法, 其运算量、参数量、模型大小分别降低了 35.96%、25.63%、23.22%, 安全帽检测的平均精度未降低且有 0.05% 的提升。

1 YOLOv8 算法分析

YOLOv8 是 2023 年 1 月推出的 YOLO 新版本, 由 Ultralytics 提供。YOLOv8 支持全方位的视觉人工智能 (artificial intelligence, AI) 任务, 包括检测、分割、姿态估计、跟踪和分类。同 YOLOv5 一样, 基于缩放系数提供了 N/S/M/L/X 尺度的不同大小模型, 用于满足不同的场景需求。其结构如图 1 所示。

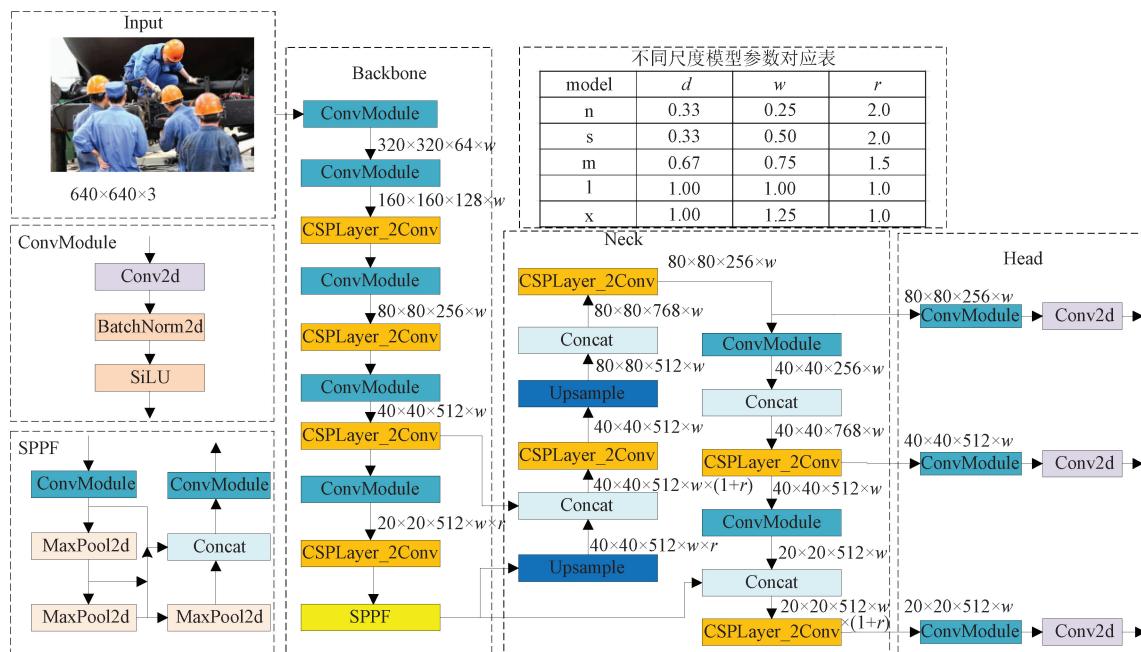


图 1 YOLOv8 算法结构示意图

Fig. 1 YOLOv8 algorithm structure diagram

YOLOv8 的 Neck 层及 Head 层采用主流解耦头结构, 分类与检测头分离。对比 YOLOv5 有以下改进: 将目

标检测方式基于描点换成了无描点; 在损失值计算方面采用了任务协调分配策略, 引入分布焦距损失; 训练的数据

增强部分最后 10 次关闭马赛克增强操作,有效地提升精度;骨干层将所有的 C3(CSP bottleneck with 3 convolutions)模块换成 C2f(faster implementation of CSP bottleneck with 2 convolutions)。这些优化使得 YOLOv8 具有较高的检测精度及实时性。

2 算法的创新与改进

为解决安全帽佩戴目标检测算法中参数多,计算量大、推理速度慢导致的难以部署在低性能嵌入式平台的问题,对 YOLOv8 的主干层、颈部、Head 层都做了相应改进。

2.1 主干层的改进

主干层负责从输入图像中提取特征,是后续网络层进行目标检测的基础。为实现轻量化优化,利用 MobileNetv3 中的倒残差结构优化主干网络。MobileNetv3 是一种轻量级神经网络^[14],其结合了深度可分离卷积和逐点卷积,具有计算量小及表征能力强的特点。

倒残差模块结构如图 2 所示,首先采用 1×1 卷积升维,然后通过 3×3 逐深度(depthwise, DW)卷积,通道数保持不变,最后通过 1×1 卷积降维,呈现两头小中间大的结构。

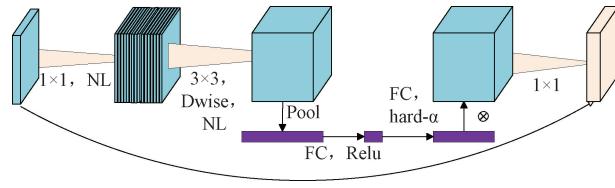


图 2 倒残差结构

Fig. 2 Inverted residual block

MobileNetv3 中引入非线性激活函数 $h\text{-swish}(x)$,其公式如式(1)所示。其非线性在保持精度的情况下带来许多优势,且修正线性单元(rectified linear unit 6, ReLU6)在硬件框架中都能实现,避免了量化时数值精度的损失。

$$h\text{-swish}[x] = x \frac{\text{ReLU6}(x+3)}{6} \quad (1)$$

MobileNetv3 结构中可选择加入了轻量级注意力机制 SENet^[15]。SeNet 对所有通道进行全局平均池化,让其拥有全局感受视野,使得浅层网络具有全局信息;结构如图 3 所示,输入通过全局平均池化(global average pooling, GAP)、全连接层(fully connected layers, FC)、ReLU 及 $h\text{-swish}$ 为所有通道生成各自的权重。

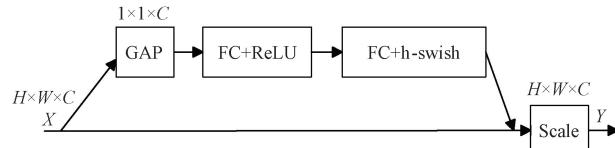


图 3 SENet 注意力机制结构

Fig. 3 SENet attention mechanism structure

用残差结构及快速空间金字塔池化(spatial pyramid pooling fast, SPPF)模块构建新的主干层,其结构如图 4。

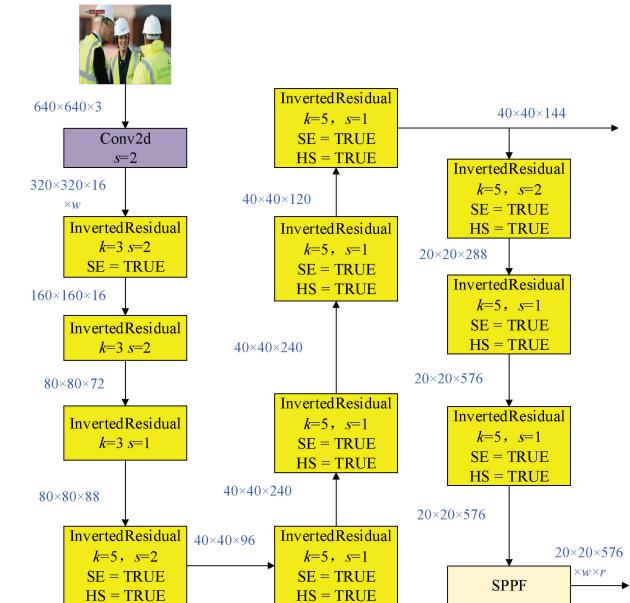


图 4 YOLOv8 轻量化后的主干层结构

Fig. 4 YOLOv8 lightweight backbone layer structure

其中 SE=True 表示子模块中引入 SENet 注意力机制, HS=True 表示使用 $h\text{-swish}$ 激活函数。经计算,网络优化主干层后的参数量为 2 354 532,计算量为 5.8 GFLOPs。原始的 YOLOv8n 网络参数量为 3 157 200,计算量为 8.9 GFLOPs。优化后的网络参数量减少了 25.4%,计算量减少了 34.83%,实现对网络的轻量化优化。

2.2 优化特征融合模块

YOLOv8 的多尺度特征融合模块基于路径聚合网络(path aggregation network, PANet),其结构如图 5(a)所示。其上采样和下采样操作之间的信息流传递为单向传递,在训练过程中对于安全帽小目标的特征信息融合较差。单节点获取的信息并不多,却增加了模型的参数。针对这些问题引入加权双向金字塔(bidirectional feature pyramid network, BiFPN)^[16]。BiFPN 结构如图 5(b)所示,其中每层节点的 I、T、O 分别表示输入节点、中间节点及输出节点。

与 PANet 相比,BiFPN 模块删除了特征融合能力弱的边缘节点,实现了不同层级之间信息的传递。边缘节点的删除减小了模块的大小及计算量,利于轻量化设计。BiFPN 模块引入可学习的权值来学习不同输入特征的重要性能,其加权特征融合公式如式(2)所示。

$$O = \sum_i \frac{w_i}{\epsilon + \sum_j w_j} I_i \quad (2)$$

其中, w_i 与 w_j 表示不同的权重学习参数, ϵ 为常数值, I_i 表示输入特征。 ϵ 为极小值 0.001 保证了结果的稳定。在图 5(b)中,第 6 节点的特征融合机制如式(3)所示。

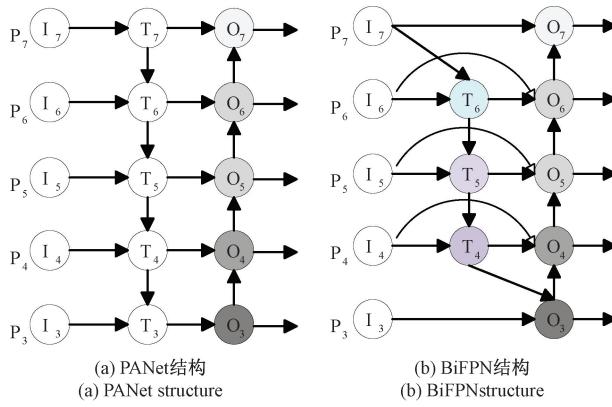


图 5 特征融合模块结构对比图

Fig. 5 Feature fusion module structure comparison chart

$$\left\{ \begin{array}{l} T_6 = \text{Conv}(\frac{w_1 \cdot I_6 + w_2 \cdot R(I_7)}{w_1 + w_2 + \epsilon}) \\ O_6 = \text{Conv}(\frac{w'_1 \cdot I_6 + w'_2 \cdot T_6 + w'_3 \cdot R(T_5)}{w'_1 + w'_2 + w'_3 + \epsilon}) \end{array} \right. \quad (3)$$

其中, T_6 为第 6 级的中间特征, O_6 为第 6 级的输出特征, Conv 为可分离卷积, R 为上采样或下采样, w, w' 为权重学习参数。

2.3 引入注意力机制

YOLOv8 算法中 head 层负责生成最终的检测结果, 其根据 Backbone 层和 Neck 层提取的特征信息预测最终结果。为提高模型的检测性能, head 层的特征融合后加入注意力机制, 增强有效信息的利用。为兼顾轻量化设计, 采用无参注意力机制 SimAM。

SimAM 在不增加网络参数的情况下增强模型的学习能力, 与常用的卷积块注意模块 (convolutional block attention module, CBAM) 相比, 其框架结构完全不同。SimAM 采用三维注意力模块, 其结构如图 6 所示。

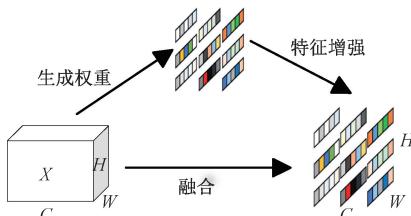


图 6 SimAM 注意力结构示意图

Fig. 6 SimAM attention structure diagram

利用相邻像素之间具有较强的相似性这一特性, 通过计算特征图中每个像素与其相邻像素之间的相似性来生成注意力权重, 每个神经元分配唯一的权重, 定义能量函数 e_i^* 对第 i 个神经元评估其重要性, 如式(4)所示。

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t_i - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (4)$$

其中, λ 为正则项, t_i 为输入特征图在单个通道上的第 i 个神经元; $\hat{\mu}$ 和 $\hat{\sigma}$ 为所有神经元在单通道上的平均值

和方差, 若神经元个数为 T , 则计算公式如式(5)所示。

$$\left\{ \begin{array}{l} \hat{\mu} = \frac{\sum_{i=1}^T x_i}{T} \\ \hat{\sigma}^2 = \frac{\sum_{i=1}^T (x_i - \hat{\mu})^2}{T} \end{array} \right. \quad (5)$$

e_i^* 值越大, 表示该神经元与周围神经元的区别越小, 重要程度越低, 将其取倒数作为权重系数, 同时使用 sigmoid 激活函数限制其大小, 最终公式如式(6)所示。

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (6)$$

其中, X 为输入特征图, E 为输入特征图所有神经元 e_i^* 值的集合, \tilde{X} 为新的特征图。

2.4 YOLOv8-MBS 网络结构

改进 YOLOv8 算法的最终结构参数如表 1 所示。

表 1 中 from 表示输入来源, -1 代表输入来自上一层, params 表示对应子模块的参数量, module 为子模块名称, arguments 表示模块的参数信息。

3 实验与分析

3.1 实验平台及数据集

实验的硬件环境及训练的超参数设置如表 2 所示。

公开安全帽数据集有 SHWD、Safety Helmet Detection 及 Helmet Dataset 数据集。SHWD 数据集的样本数最多, 选用此数据集可提高算法泛化能力及性能。

SHWD 的图片来自实际场地和网络爬取, 总 7 581 张图像, 其尺寸不一致, 处理时先对图片进行等比例缩放 (宽/高至 640)。数据集中包含 9 044 个人体安全头盔佩戴对象 (正面) 和 111 514 个正常头部对象 (未佩戴或负面)。类别包含佩戴安全帽的人 (hat) 以及未佩戴安全帽的人 (person), 同时又从互联网筛选一些具有复杂的施工环境和目标密集的图片来做补充, 并将数据集随机按照 8 : 1 : 1 的比例划分为训练集、验证集、测试集。

3.2 评估指标

采用均值平均精度 (mAP)、准确率 (Precision)、召回率 (Recall)、参数量 (Params)、计算量 (giga floating-point operations per second, GFLOPs) 及帧率 (frames per second, FPS) 为模型性能的评估指标, 公式如式(7)所示。

$$\left\{ \begin{array}{l} \text{Precision} = \frac{TP}{TP + FP} \\ \text{Recall} = \frac{TP}{TP + FN} \\ AP = \int_0^1 P(R) dR \\ mAP = \frac{\sum_{i=1}^k AP_i}{K} \\ FPS = \frac{1000}{pr + inf + pos} \end{array} \right. \quad (7)$$

表 1 YOLOv8n-MBS 结构参数
Table 1 YOLOv8n-MBS structural parameters

序号	from	params	module	arguments
0	-1	232	Conv_BN_	3, 8, 2
1	-1	628	InvertedResidual	8, 8, 16, 3, 2, 1, 0
2	-1	2 104	InvertedResidual	8, 8, 72, 3, 2, 0, 0
3	-1	2 568	InvertedResidual	8, 8, 88, 3, 1, 0, 0
4	-1	9 848	InvertedResidual	8, 16, 96, 5, 2, 1, 1
5	-1	43 772	InvertedResidual	16, 16, 240, 5, 1, 1, 1
9	-1	43 772	InvertedResidual	16, 16, 240, 5, 1, 1, 1
7	-1	14 702	InvertedResidual	16, 16, 120, 5, 1, 1, 1
8	-1	19 364	InvertedResidual	16, 16, 144, 5, 1, 1, 1
9	-1	61 752	InvertedResidual	16, 24, 288, 5, 2, 1, 1
10	-1	211 008	InvertedResidual	24, 24, 576, 5, 1, 1, 1
11	-1	211 008	InvertedResidual	24, 24, 576, 5, 1, 1, 1
12	-1	13 112	SPPF	24, 256, 5
13	-1	0	Upsample	None, 2, 'nearest'
14	-1, 8	2	BiFPN_Concat2	1
15	-1	133 888	C2f	272, 128, 1
16	-1	0	Upsample	None, 2, 'nearest'
17	-1, 3	2	BiFPN_Concat2	1
18	-1	33 664	C2f	136, 64, 1
19	-1	36 992	Conv	64, 64, 3, 2
20	-1, 15	2	BiFPN_Concat2	1
21	-1	123 648	C2f	192, 128, 1
22	-1	147 712	Conv	128, 128, 3, 2
23	-1, 12	2	BiFPN_Concat2	1
24	-1	493 056	C2f	384, 256, 1
25	-1	0	SimAM	256
26	18, 21, 25	751 702	Detect	2, [64, 128, 256]

表 2 实验环境参数

Table 2 Experimental environment parameters

名称	参数
操作系统	Windows10
CPU	AMD Ryzen 7 5800x
内存	16GB
GPU	NVIDIA RTX 2080
深度学习框架	Pytorch
epochs(超参数)	300
patience(超参数)	50
batch(超参数)	32
cache(超参数)	True
iou(超参数)	0.5
imgsz(超参数)	640
augment(超参数)	True
degrees(超参数)	25.0
lr0(超参数)	0.0001 5
optimizer(超参数)	Adam

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。 AP_i 为第 i 个类别的准确率, K 为类别数。 pr 表示图像预处理时间, inf 表示图像推理时间, pos 表示图像后处理时间。

3.3 消融实验

为了验证各个改进模块对 YOLOv8n 算法的优化效果, 分别在构建的安全帽数据集上进行训练和测试。实验遵循控制变量法, 其实验结果如表 3 所示。

表 3 中, \checkmark 表示的原始 YOLOv8n 网络中混合相应改进。与原算法相比, 优化主干层后计算量及参数量都有较大幅度的降低, 其帧率提升了 12.78 fps, 但另一方面, 模型的轻量化带来了其检测精度的降低。其准确率、召回率及 mAP 分别降低 3%、11.2%、5.15%; 仅优化特征融合运算量及参数量无明显变化, 其检测精度有所提升。对比原始算法, 其准确率、召回率及 mAP 值分别提升了 1.6%、1.5%、3.52%。实验结果表明优化特征融合模块能提高算法精度。仅加入 SimAm 注意力机制后, 其运算量及参数无明显提升, 检测精度对比原始算法有所提升。对比原始算法, 其准确率、召回率及 mAP 值分别提升了 2%、1.5%、

表 3 YOLOv8n 消融实验
Table 3 YOLOv8n ablation experiment

优化主干层	优化特征融合	SimAM 注意力	Params/ 10^6	GFLOPs	准确率/%	召回率/%	mAP/%	帧率/FPS
×	×	×	3.16	8.9	89.2	83.7	87.40	168.10
√	×	×	2.35	5.7	86.2	72.2	81.95	180.88
×	√	×	3.16	8.9	90.8	84.6	90.51	168.18
×	×	√	3.16	8.9	91.2	85.2	90.92	168.06
√	√	×	2.35	5.7	88.3	75.7	84.23	180.86
√	√	√	2.35	5.7	89.9	80.2	87.45	180.83

3.5%。实验结果表明无参数注意力机制 SimAm 加入可提高安全帽检测精度,且不增加额外的计算负担;同时优化主干层与特征融合后,与仅优化主干层相比,网络模型大小及参数无变化,其准确率、召回率及 mAP 值分别提升了 2.1%、3.5%、2.28%。同时优化主干层、特征融合及加入 SimAM 注意力机制后,对比原始算法,其大小有显著下降,模型检测精度与原 YOLOv8n 相比无降低且有略微提升,其准确率及 mAP 值分别提升了 0.7%、0.05%。

实验表明,YOLOv8-MBS 算法主干层的优化减小了算法的计算量及参数量,实现了模型的轻量化。同时优化特征融合网络和引入 SimAM 注意力机制的改进,增强了算法的学习能力及检测性能,弥补了算法轻量化后造成的检测精度下降。

3.4 实验结果及分析

为测试 YOLOv8-MBS 算法实际检测效果,测试集中选取 3 张具有代表性场景的图片进行检测,分别是密集人群场景、安全帽未佩戴场景、复杂工地场景。其实验结果如图 7 所示,左图为待检图片,右图为检测结果。

由图 7(a)检测结果可看出,YOLOv8-MBS 算法在密集人群场景下能准确检测出所有安全帽佩戴情况,具备在人群密集场所应用的能力;图 7(b)中未佩戴的安全帽未检测,而背景中正常穿戴的安全帽能正确识别,符合实际应用要求;图 7(c)在复杂工地场景下,钢筋遮挡部分安全帽图像的情况下,算法也能正确识别出安全帽的佩戴情况。表明算法具备在复杂工地现场应用的能力。根据实验结果可知,此算法满足应用需求。

为进一步验证算法的性能,使用原算法和改进后算法在测试集上进行测试,结果对比如图 8 所示。其中第 1 行为原始算法的检测结果,第 2 行为算法优化后的检测结果。检测结果的差异在原始检测结果图中用黑色箭头标出。图 8(a)中为工地复杂施工环境下的检测结果。原始算法未检测到图片中所有安全帽的佩戴情况,对于部分图像被钢筋遮挡的安全帽漏检,而优化过的算法成功识别到所有安全帽;图 8(b)中,原始算法将腰部的衣物误检为安全帽,而优化过的算法未误检;图 8(c)中原始算法将角落口袋系误判为安全帽,而优化过的算法正常识别未误判,同时检测到图中所有安全帽。



图 7 不同场景下安全帽佩戴检测结果

Fig. 7 Safety helmet wearing test results in different scenarios

为进一步测试算法改进后的漏检率及误检率,在验证集中随机选取 300 张图片进行测试,共 997 个目标。算法改进前后的漏检率、漏检数、误检率和误检数结果表 4 所示。其中漏检数减少了 31,误检数减少了 14。实验结果表明优化后的算法误检、漏检情况有所改善。

3.5 与其他算法的对比

为比较 YOLOv8-MBS 算法与主流的深度学习算法在此数据集上的检测性能,再次进行了对比实验。实验遵循控制变量原则,实验软硬件环境不变,评价指标采用准确率、平均准确率、参数量、运算量、帧率。为测试不同模型训练后的内存占用情况,增加模型大小(model size)指标。实验结果如表 5 所示。

由实验结果可知,针对安全帽检测,YOLO 系列算法整体优于 Faster R-CNN,其在运算量及精度方面都优于



图 8 优化前后网络检测结果对比

Fig. 8 Comparison of network detection results before and after optimization

表 4 漏检误检测试结果

Table 4 Missed detection and false detection test results

模型	漏检率/ %	漏检数	误检率/ %	误检数
YOLOv8n	15.24	152	11.23	112
YOLOv8-MBS	12.13	121	9.83	98

Faster R-CNN。YOLO 系列中检测精度最高的为 YOLOv8x,但其计算量达到了 258.1 GFLOPs,不适用与

嵌入式部署。本文提出的算法 YOLOv8-MBS 参数量、运算量、模型大小均为最小,同时检测精度方面优于 YOLOv3、YOLOv6、YOLOv5s、YOLOv8n。本文算法与祁泽政等^[17]提出的算法对比,其参数量和运算量分别降低了 75.7%、79.1%,而精度仅下降了 0.3%。

综合来看,当运行平台资源受限时,优化后的算法 YOLOv8-MBS 具有极大的优势。与其他主流算法相比,YOLOv8-MBS 对平台资源要求最小,同时保持较高的检测精度,满足实际使用。

表 5 YOLOv8-MBS 与主流算法评价指标对比

Table 5 Comparison of evaluation indicators between YOLOv8-MBS and mainstream algorithms

模型	准确率/%	mAP@0.5/%	Params/10 ⁶	GFLOPs	Model size/MB	帧率/FPS
YOLOv5s	88.6	87.12	9.12	23.8	21.45	154.80
YOLOv5x	91.2	90.11	86.21	217.9	278.32	24.60
YOLOv8n	89.2	87.40	3.16	8.9	6.20	168.10
YOLOv8s	90.1	89.02	11.17	28.8	21.53	152.61
YOLOv8l	92.6	93.42	43.69	165.7	83.70	55.57
YOLOv8x	93.0	94.91	68.23	258.1	130.36	34.28
YOLOv3	87.6	85.26	103.67	282.2	198.12	22.40
YOLOv6	87.9	86.31	4.23	11.8	8.27	160.50
Faster R-CNN	82.4	76.71	60.12	282.7	354.21	22.10
文献 17	90.2	89.28	9.71	27.2	24.45	152.80
YOLOv8-MBS	89.9	87.44	2.35	5.7	4.76	180.62

4 结 论

针对当前安全帽佩戴检测由于算法对平台资源要求高造成部署成本较高,从而难以广泛应用的问题。首次提出一种将 MobileNetv3 和 YOLOv8 相结合,使用高效加权双向特征金字塔及嵌入了 SimAM 注意力机制的算法 YOLOv8-MBS。利用 MobileNetv3 优化主干模块,大幅度的降低了算法的参数量和计算量;使用 BiFPN 高效加权双向特征金字塔提高网络的特征融合能力;加入无参数

SimAM 注意力机制,提高小目标安全帽的检测精度的同时保持模型轻量化的特点。

本文提出的算法对运行平台的资源要求极低,具有极低的计算量、参数量及较小的模型体积。最终优化后的模型体积仅 4.76 MB,有利于后续模型的嵌入式部署。对部署平台资源要求的降低,可减少网络部署成本及应用成本,推动其在实际中应用。后续将继续提高模型精度,并尝试部署至硬件设备。

参考文献

- [1] 侯学良,单腾飞,薛靖国.深度学习的目标检测典型算法及其应用现状分析[J].国外电子测量技术,2022,41(6):165-174.
- HOU X L, SHAN T F, XUE J G. Analysis of typical deep learning-based object detection algorithms and their application status [J]. Foreign Electronic Measurement Technology, 2022,41(6):165-174.
- [2] RUBAIYAT A H M, TOMA T T, KALANTARI-KHANDANI M, et al. Automatic detection of helmet uses for construction safety [C]. International Conference on Web Intelligence Workshops, 2016: 135-142.
- JIA J S, BAO Q J, TANG H M. Method for detecting safety helmet based on deformable part model[J]. Application Research of Computers, 2016, 33(3):953-956.
- FANG L J, LIN T W, WU J, et al. A DPM based approach to joint object detection and sub-category recognition [C]. IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), 2017: 164-168.
- GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- 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.
- ZHANG Y T, HUANG D Q, WANG D W, et al. Review on research and application of deep learning-based target detection algorithms [J]. Computer Engineering and Applications, 2023,59(18):1-13.
- 朱栋,贺森.基于改进 YOLOv5 的太阳能电池板缺陷检测算法[J].国外电子测量技术,2024,43(3):76-82.
- ZHU D, HE S. Defect detection algorithm for solar panels based on improved YOLOv5 [J]. Foreign Electronic Measurement Technology, 2024, 43 (3): 76-82.
- 李振华,张雷.改进 YOLOv3 的安全帽佩戴检测方法[J].国外电子测量技术,2022,41(12):148-155.
- LI ZH H, ZHANG L. Safety helmet wearing detection method of improved YOLOv3 [J]. Foreign Electronic Measurement Technology, 2022, 41 (12): 148-155.
- [10] 王晓龙,江波.基于改进 YOLOX-m 的安全帽佩戴检测[J].计算机工程,2023,49(12):252-261.
- WANG X L, JIANG B. Safety helmet wearing detection based on improved YOLOX-m[J]. Computer Engineering,2023,49(12):252-261.
- [11] 左明成,焦文华.面向煤矿井下作业场景的安全帽佩戴识别算法[J].中国安全科学学报,2024, 34 (3): 237-246.
- ZUO M CH, JIAO W H. Helmet-wearing recognition algorithm for coal mine underground operation scenarios[J]. China Safety Science Journal, 2024, 34(3):237-246.
- [12] 刘昶成,邵文权,李玲陶.基于改进 YOLOv5s 的电力作业人员安全帽检测算法研究[J].国外电子测量技术,2024,43(2):34-42.
- LIU CH CH, SHAO W Q, LI L T. Research on safety helmet detection algorithm for power operators based on improved YOLOv5s[J]. Foreign Electronic Measurement Technology, 2024,43(2):34-42.
- [13] 王媛彬,韦思雄,吴华英,等.基于改进 YOLOv5s 的矿井下安全帽佩戴检测算法[J/OL].煤炭科学技术,1-11 [2024-05-12]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240322.1607.005.html>.
- WANG Y B, WEI S X, WU H Y, et al. Detection algorithm for wearing safety helmet under mine based on improved YOLOv5s [J/OL]. Coal Science and Technology,1-11 [2024-05-12]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240322.1607.005.html>.
- [14] KOONCE B. Convolutional neural networks with swift for tensorflow: Image recognition and dataset categorization[M]. California:Apress,2021.
- TAN M X, CHEN B, PANG R M, et al. MnasNet: Platform-aware neural architecture search for mobile[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR),2019:2815-2823.
- [16] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020: 10781-10790.
- [17] 祁泽政,徐银霞.改进 YOLOv5s 算法的安全帽佩戴检测研究[J].计算机工程与应用,2023, 59 (14): 176-183.
- QI Z ZH, XU Y X. Research on helmetwearing detection of improved YOLOv5s algorithm [J]. Computer Engineering and Applications, 2023, 59(14):176-183.

作者简介

张国鹏,硕士研究生,主要研究方向为图像处理。

E-mail: 942536987@qq.com

周金治(通信作者),硕士研究生,教授,主要研究方向为信号处理、通信网络、机器学习等。

E-mail: zhoujinzh@swust.edu.cn

马光岑,硕士研究生,主要研究方向为图像处理。

贺浩洋,硕士研究生,主要研究方向为图像处理。