

融合知识蒸馏和注意力机制的安全帽佩戴检测

刘岩^a, 周孟然^b

安徽理工大学 a. 人工智能学院; b. 电气与信息工程学院, 安徽 淮南 232001

摘要:目的 为了解决变电所场景下因模型参数量过大、推理时间较长导致错检和漏检问题较高等问题, 提出一种基于知识蒸馏和注意力机制的变电所安全帽佩戴实时检测算法 YOLO-FE(BCKD)。方法 为了减少模型的大小和推理速度, 使用 FasterNet block, 去替换原本骨干网络和 NECK 部分中的 C2f 模块; 为了减少因为降低模型参数而导致精度大幅下降的问题, 使用高效多尺度的 EMA 注意力机制加入骨干网络之中, 提高模型提取特征的能力; 最后为了让模型能具有更高的精度, 选择 YOLOv8m 作为教师网络, YOLO-FE 作为学生网络, 使用 BCKD 知识蒸馏方法对 YOLO-FE 进行知识蒸馏。结果 该研究使用在煤矿变电所收集到的安全帽数据集为基础, 选用不同算法进行对比实验。最终表明: 改进的 YOLOv8 模型未蒸馏前平均精度达到 74.5%, 相较于 YOLOv8n 提高了 2.5%, 参数量下降 26.7%, 检测速度提高 26%, 经过蒸馏之后模型的平均精度达到 75.4%。为了验证算法的泛用性, 在公开数据集 GDUT-HWD 上测试, 其精度值为 84.2%, 比原始模型提高 3%。结论 文中提出的安全帽佩戴检测算法在精度和实时性上取得了良好的平衡, 满足变电所环境下的实时检测需求。

关键词: 安全帽; YOLOv8; FasterNet; 注意力机制; 知识蒸馏

中图分类号: TM63; TP391.41 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2026.0002.010

Helmet-wearing Detection Combining Knowledge Distillation and Attention Mechanism

LIU Yan^a, ZHOU Mengran^b

a. School of Artificial Intelligence; b. School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective To address the issues of large model parameters, long inference time, and high rates of false positives and negatives in safety helmet detection in substation scenarios, a real-time helmet-wearing detection algorithm YOLO-FE (BCKD) based on knowledge distillation and attention mechanism is proposed. **Methods** In this model, to reduce the model size and inference time, FasterNet blocks were used to replace C2f modules in the original backbone network and NECK section. Furthermore, to mitigate the significant drop in accuracy due to reduced model parameters, an efficient multi-scale EMA attention mechanism was integrated into the backbone network to enhance the model's feature extraction capability. Finally, to achieve higher accuracy, YOLOv8m was selected as the teacher network and YOLO-FE as the student network, and the BCKD knowledge distillation method was adopted to distill knowledge into YOLO-FE. **Results** This study used a helmet dataset collected from coal mine substations and conducted comparative experiments with different algorithms. The results showed that the improved YOLOv8 model achieved an average precision of 74.5% before distillation, surpassing YOLOv8n by 2.5%, with a 26.7% reduction in parameters and a 26% increase in detection

收稿日期: 2024-03-11 修回日期: 2024-06-21 文章编号: 1672-058X(2026)02-0076-07

作者简介: 刘岩(1998—), 男, 安徽淮南人, 硕士研究生, 从事图像目标检测研究。

通信作者: 周孟然(1965—), 男, 安徽淮南人, 教授, 博士, 从事矿山机电系统监测、光电信息处理、煤矿安全监测监控方面研究。

Email: 1714552869@qq.com.

引用格式: 刘岩, 周孟然. 融合知识蒸馏和注意力机制的安全帽佩戴检测[J]. 重庆工商大学学报(自然科学版), 2026, 43(2): 76-82.

LIU Yan, ZHOU Mengran. Helmet-wearing detection combining knowledge distillation and attention mechanism[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2): 76-82.

speed. After distillation, the model's average precision reached 75.4%. To verify the algorithm's generalizability, it was tested on the public dataset GDUT-HWD, achieving an accuracy of 84.2%, a 3% improvement over the original model.

Conclusion The proposed helmet-wearing detection algorithm achieves a good balance between accuracy and real-time performance, meeting the requirements for real-time detection in substation environments.

Keywords: helmet; YOLOv8; FasterNet; attention mechanism; knowledge distillation

对于电力系统的从业人员而言,佩戴安全帽是一项关系人身安全的重要措施。但是实际中,往往因为疏忽懈怠等原因不佩戴安全帽进行生产作业,导致出现安全事故。传统检测方法主要通过委派安全监管人员使用视频监控来对不佩戴安全帽的行为进行监督。但是面对大量的监控画面,人难免会有疏忽,很难彻底对不佩戴安全帽的行为进行及时监管。

随着深度学习技术的发展,目标检测技术较过去有了很大的进步,于是越来越多的国内外学者将基于深度学习的目标检测技术应用到安全帽佩戴检测中。目前基于深度学习的目标检测算法有两种:一种是基于候选区域的两阶段(Two-stage)算法,如 R-CNN^[1]、Fast-RCNN^[2]和 Faster-RCNN^[3]等;另一种是基于回归的单阶段(One-stage)检测算法,如 YOLO^[4-7]和 SSD^[8]系列算法。因为单阶段算法模型较为简单,检测速度更快,同时精度也保持得很好,更被工业界和学术界所青睐。在单阶段算法中,YOLO 家族算法最为流行,许多学者根据应用场景的不同对 YOLO 算法进行相应地改进。施辉等^[9]在 YOLOv3 的基础上,使用图像金字塔模块,融合不同尺度的特征图,提高了安全帽佩戴检测的准确性;金雨芳等^[10]通过修改特征图输出和特征融合模块,提高了 YOLOv4 的检测精度。

随着目标检测技术的不断发展,检测模型对于硬件算力的要求也在不断提高,但这些复杂模型难以应用到工业环境中。因此,模型压缩的概念便应运而生。知识蒸馏是现如今最常用的模型压缩技术之一,使用教师-学生的方法,通过计算教师模型和学生模型预测结果的差值作为损失进行计算,来进行梯度的更新,让教师模型学到的知识迁移到学生模型之中。杨永波等^[11]使用 MobileNetV3 替换 YOLOv5s 的主干网络,使用知识蒸馏增加模型的检测精度,达到轻量化的目的。

上述算法虽然在安全帽佩戴检测上都取得了不错的结果,但普遍出现了检测速度和精度难以平衡的问题。针对以上出现的问题,将 FasterNet 和注意力机制融合进 YOLOv8,减少其模型参数,同时利用知识蒸馏技术去提高算法的检测精度,从而让模型的检测精度

和速度达到较好的平衡。

1 YOLOv8 算法及其改进

YOLOv8 是 Ultralytics 公司在 2023 年提出的模型。和之前的 YOLOv5 算法一样,为了满足不同应用场景的需求,其基于缩放系数提供了 5 个不同大小的模型。本文基于部署的需求,使用 YOLOv8n 作为改进的基础模型。

YOLOv8 是如今检测效果最好的算法,它的网络结构由 Backbone 网络、Neck 网络和 Head 网络组成。

其 Backbone 的总体框架源于 YOLOv3 的 DarkNet-53。经过多年发展,YOLOv8 在 DarkNet-53 的基础上对卷积结构进行改进。YOLOv8 如今的 Backbone 可以分成 CBS、C2f 和 SPPF 三个模块。使用卷积操作对输入的 RGB 图像进行特征提取,提取出不同尺度的特征图。

Neck 部分主要负责对提取出来的特征进行融合,其结构是 FPN^[12]和 PAN^[13]组成的 PANet^[14]。FPN 部分会将高层语义信息自顶向下进行传递,增强特征融合之后的语义信息。PAN 与之相反,将底层的定位信息自底向上进行传递,对 FPN 缺少的特征信息进行补充,增强特征融合之后的定位信息。Head 部分抛弃了 YOLOv5 的检测头,采用目前主流的解耦头结构,将分类和检测两部分分离。

为了实现在变电所环境下安全帽佩戴检测算法具有更好的检测精度和速度,提出一种 YOLOv8-FE 安全帽佩戴检测算法。YOLOv8-FE 的网络结构如图 1 所示。

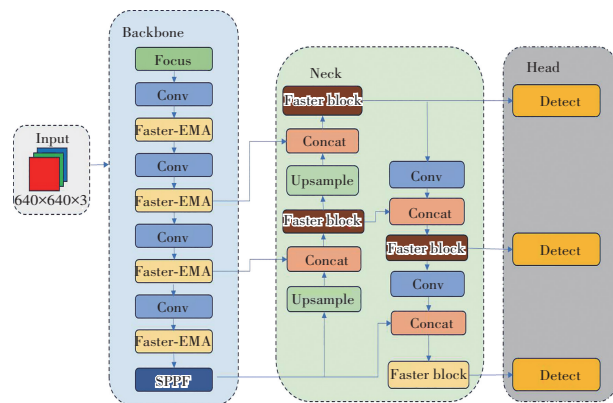


图 1 改进的 YOLOv8 算法网络结构

Fig. 1 Network structure of the improved YOLOv8 algorithm network

1.1 FasterNet block

在目标检测任务中,大部分研究为了能设计出更快速的神经网络结构,都专注于减少浮点运算数(FLOPS),但 FasterNet 发现实现更高的浮点运算数可以比仅减少 FLOPS 更能实现快速推理。现有的快速神经网络结构如深度卷积等都会带来让卷积操作频繁进行内存访问的问题。而在 FasterNet 中,提出一种新的卷积操作 PConv(Partial Convolution),并将其和逐点卷积(PWConv Pointwise Convolution)为基础组成 Faster block。这个模块可以大大减少模型内部冗余的计算和内存访问,达到更高效提取特征的目的。

PConv 只针对输入通道的一部分使用卷积核操作,对其进行空间特征提取,其余通道则保持不变,结构见图 2 所示。




图 2 PConv 结构图

Fig. 2 PConv structure

当前内存访问若是连续或者规则,则直接将第一个或者最后一个连续的 c_p 通道作为整个特征图的代表进行计算。使用这种方法大大降低了计算的复杂度。

为了让模型能更充分有效利用输入通道的所有信息,FasterNet block 会在 PConv 之后添加 2 个 PWConv 层。其结构如图 3 所示。

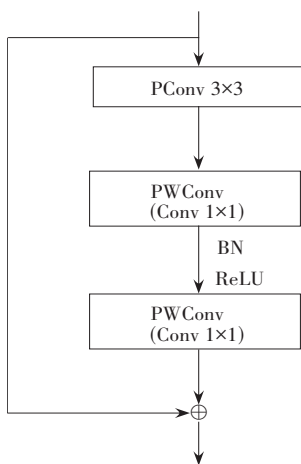


图 3 FasterNet block 结构图

Fig. 3 FasterNet block structure

PWConv 会对之前所有通道的特征信息进行计算。通过使用这种一部分进行 PConv 卷积,后续全部使用 PWConv 进行卷积的操作,能让在输入特征图上的感受野看起来像一个 T 型卷积,其感受野见图 4 所示。常规卷积模块是对特征图所有通道进行均匀处理,而这

个 PConv 和 PWConv 组合产生的 T 型结构会专注于中心位置。




图 4 FasterNet block 感受野

Fig. 4 Receptive field of FasterNet block

1.2 EMA 注意力机制

为了保证模型在降低参数数量的情况下,依旧能保持较好的特征提取能力,在骨干网络的 FaseterNet block 中加入 EMA(Efficient Multi-scale Attention)注意力机制来让模型减少对无用信息的关注,更好地注意到图像中的重要信息。

EMA 注意力机制是一种高效的多尺度注意力机制,旨在减少模型计算开销的同时能更好保留每个通道的关键信息,从而实现在参数减少的同时仍能保持较好的识别效果。EMA 会将输入特征的部分通道重塑成批次维度,将通道维度分为包含多个子特征的特征组,使用跨纬度交互的方式去捕捉特征中的像素级关系。其模块中构建了一个并行结构,用以编码全局信息,重新校准各通道的权重,帮助模型增强特征表达的能力。EMA 注意力机制的结构如图 5 所示。

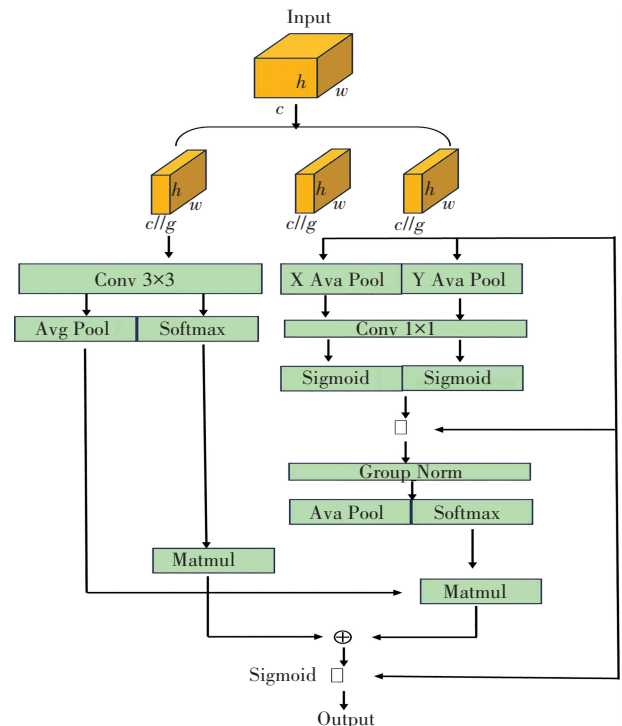


图 5 EMA 结构图

Fig. 5 EMA structure

1.3 BCKD 知识蒸馏

为了让模型能有更好的检测精度,使用 BCKD(Bidirectional Collaborative Knowledge Distillation)知识

蒸馏算法对改进后 YOLOv8 算法进行蒸馏处理。

使用 YOLOv8m 作为教师模型,用它训练好后的输出概率分布作为知识信息帮助学生模型 YOLOv8-FE 进行模型训练,用以达到更好的预测效果。

BCKD 知识蒸馏是一种基于 Logit 的蒸馏方法。其损失可以分为分类蒸馏损失和定位蒸馏损失两种。

1.3.1 分类蒸馏损失

在目标检测过程中会提取特征图,其大小为 $H \times W \times K$, H 是特征图的高度, W 是宽度, K 是数量。对于样本 X , 经过教师模型和学生模型之后得到的概率值分别为 l^t 和 l^s , 然后经过 Sigmoid 函数计算得到 $n \times K$ 大小的 p^t 和 p^s , 使用交叉熵进行分类蒸馏的计算, 公式如下:

$$L_{cls}^{dis}(x) = \sum_{i=1}^n \sum_{j=1}^K L_{BCE}(p_{i,j}^s, p_{i,j}^t) \quad (1)$$

$L_{cls}^{dis}(x)$ 是分类蒸馏损失, $p_{i,j}^s$ 和 $p_{i,j}^t$ 代表着 p^s 和 p^t 的第 i 个位置的第 j 类。为了能更好地提取最重要的样本, 使用 Focal loss 的方式, 对损失进行加权计算。对于样本 X , 它的重要性权重为 $w \in \mathbf{R}^{n \times K}$, 计算 w 的公式如下:

$$w = |p^t - p^s| \quad (2)$$

将 w 中的每个权重元素加权到损失公式之中, 可以得到最终的损失公式, 如下所示:

$$L_{cls}^{dis}(x) = \sum_{i=1}^n \sum_{j=1}^K w_{i,j} \cdot L_{BCE}(p_{i,j}^s, p_{i,j}^t) \quad (3)$$

1.3.2 定位蒸馏损失

BCKD 和之前的蒸馏算法不同, 使用无特殊检测头的定位损失蒸馏。

在定位蒸馏中, 使用两个模型输出边界框之间的 IoU 作为蒸馏目标。对于样本 X , 将第 i 个位置的教师模型和学生模型得到的相应定位预测为 o_i^t 和 o_i^s 。然后使用 anchor 的位置和得到的定位预测通过解码器获得样本 X 的预测边界框, 其过程如下:

$$b_i^t = \text{Decoder}(A_i, o_i^t) \quad (4)$$

$$b_i^s = \text{Decoder}(A_i, o_i^s) \quad (5)$$

式(4)中, A_i 是第 i 个 anchor, b_i^t 和 b_i^s 为教师模型和学生模型得出的预测框。计算两个预测框之间的 IoU, 记为 u_i , 然后再用此前用过的损失加权策略, 对重要样本提高权重, 将这个思路也应用到定位蒸馏的损失计算之中, 就可以得到式(6):

$$L_{loc}^{dis}(x) = \sum_{i=1}^n \sum_{j=1}^K w_{i,j} \cdot (1 - u_i) \quad (6)$$

在得到最终分类蒸馏损失和基于 IoU 的定位蒸馏损失之后, 将二者加权组合, 用以提高模型分类和定位能力, 总的蒸馏损失公式如式(7)所示:

$$L_{total}^{dis}(x) = \alpha_1 \cdot L_{cls}^{dis}(x) + \alpha_2 \cdot L_{loc}^{dis}(x) \quad (7)$$

最终基于知识蒸馏的 YOLOv8 算法训练框架如图 6 所示。

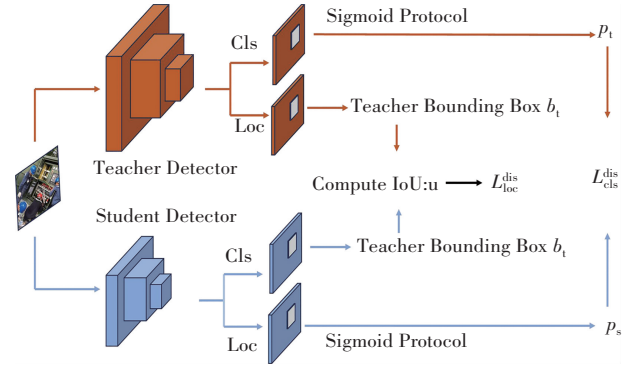


图 6 YOLOv8-FE 知识蒸馏算法框架
Fig. 6 Knowledge distillation of YOLOv8-FE algorithm framework

2 仿真实验与结果分析

本文实验平台 Ubuntu 为 20.04.4 版本, GPU 型号为 GTX2080TI, CUDA 版本为 11.7, Pytorch 版本为 1.11, 输入批次大小为 8, 设置训练迭代次数为 100 次, 模型优化器选择 SGD, 初始学习率为 0.01, 动量参数为 0.937, 权重衰减为 0.00005。

2.1 实验数据集

为了更适用于变电所真实环境, 课题组前往现场进行监控收集, 截取监控视频中的关键帧, 总共 3 000 张图片, 由佩戴安全帽以及未佩戴安全帽人员的图片组成, 使用 Labelme 进行标注。所有的对象类别按要求划分成安全帽、无安全帽和人。输入图片的尺寸在预处理之后统一设置为 640×640 , 将训练集、测试集和验证集以 8:1:1 的比例设置。部分数据集如图 7 所示。



图 7 变电所安全帽数据集部分图片

Fig. 7 Selected images of the substation safety helmet dataset

2.2 评价指标

评价网络检测精度的指标主要有精准率 P , 召回率 R , 平均精度均值 mAP。本次任务是多分类问题, 检测结果可以分为 4 类。 T_p (真正例)、 F_N (反假例)、 F_p (假正例) 和 T_N (真反例) P 和 R 的公式如(8)和式(9)所示:

$$P = \frac{T_p}{T_p + F_p} \quad (8)$$

$$R = \frac{T_p}{T_p + F_N} \quad (9)$$

使用召回率和精准率作为横坐标和纵坐标, 其形

成的曲线被称为 P-R 曲线。将曲线下方围成的面积,称为平均精度值(L_{AP}),其计算见式(10)。将各个类别的平均精度值进行求和,再除以总数就能得到平均精度均值,见式(11)。

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

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

2.3 注意力机制对比

为了证明 EMA 注意力机制对网络模型在安全帽佩戴检测的性能有提升作用,选取不同注意力机制如 CA^[15]、ECA^[16]和 CBAM^[17]进行对比实验。

从表 1 可以看出:注意力机制对模型的性能提升较大,EMA 注意力的提升最大,其 L_{mAP} 值达到 74.5%,其他注意力机制的效果稍逊一筹。为了更加直观对比注意力机制对模型性能的提高效果,生成对应热力图像,如图 8 所示。

表 1 注意力对比实验

注意力机制	P	R	L_{mAP}
—	74.1	66.1	71.9
CA	75.9	69.0	74.0
ECA	76.5	67.3	73.7
CBAM	75.7	68.8	74.2
EMA	75.8	68.9	74.5




图 8 注意力对比热力图

Fig. 8 Attention contrast heat maps

从图 8 可以明显看出:使用注意力机制后能让网络模型更好地聚焦到重要信息上。其中 EMA 注意力对比其他注意力,其在安全帽上的热力值更高,对其他地方的热力值更少,同时预测分数也更高,表明 EMA 能更好地把注意力集中在待检测目标上,定位也更准确,大大提高了模型对安全帽目标的聚焦,提高了 Backbone 的特征提取能力。

2.4 模型消融实验

为了分析模型内部结构的改进对模型性能的提升

作用,设计了针对模型结构改进的消融实验。结果如表 2 和表 3 所示。

表 2 模块消融实验

Table 2 Ablation experiment

方法	参数量/ 10^6	推理速度/ms	L_{mAP}
—	3.15	20	0.711
Fblock	2.45	15	0.71
EMA	2.81	18	0.732
F+E	2.15	16	0.745

表 3 PConv 对比实验

Table 3 PConv comparison experiment

C_p/C	推理速度/ms	$L_{mAP}/\%$
1/2	18	71.1
1/4	15	71.0
1/8	13	70.5

表 2 中,第一行为原始模型,第二行为加入 FasterNet block 的结果,第三行是只加入 EMA 的结果,第四行为使用 FasterNet block 和 EMA 组成的 FE block。可以从表中清楚看出:FasterNet block 和 EMA 机制都有降低模型参数和加速模型推理的作用,FasterNet block 的作用更明显,但是会降低模型的精度,而 EMA 对模型的精度能起到提高作用。综合利用二者的优势,FasterNet block 和 EMA 共同作用下,最终模型的精度提高 3.5%,参数量减少 26.7%,同时推理速度较之原始 YOLOv8n,减少 4ms,减少了 20%。

表 3 为 Fblock 内部 PConv 对做卷积和不做卷积的通道数之比的对比实验。采取 3 种不同的比值,可以看出在比值为 1/2 时,模型的推理速度较慢;当比值为 1/8 的时候,模型的推理速度较快,但是精度会下降。综合精度和推理速度,选择比值 1/4 为最佳。

2.5 蒸馏实验

为提高模型的精度,对模型进行知识蒸馏操作。使用 L_1 、 L_2 和 BCKD 知识蒸馏对模型进行对比实验,验证 BCKD 蒸馏效果的优势,结果如表 4 所示。第一行是 YOLOv8-FE 模型的结果, L_1 蒸馏是对两个模型的输出作 MAE 损失, L_2 蒸馏是对两个模型的输出做 MSE 损失。从表中可以看出:BCKD 蒸馏由于采用了正负样本平衡的思想,对目标的检测精度提高最大,比之未蒸馏的模型提高了 0.9 个百分点。

表 4 蒸馏实验

Table 4 Distillation experiment

方法	P	R	L_{mAP}
—	75.8	68.9	74.5
L_1	77.2	68.7	74.6
L_2	75.5	67.5	74.3
BCKD	77.7	69.3	75.4

2.6 与其他模型的对比试验

为了更进一步验证改进算法的有效性,使用主流目标检测算法进行对比,检测效果如表 5 所示。

表 5 对比实验

Table 5 Comparison experiment

模 型	参数量 /10 ⁶	推理速 度/ms	L _{AP} /%			精 度
			Hat	People	None	
YOLOv3-tiny	12.1	22	50.6	81.8	35.3	55.9
YOLOv5s	7.2	25	63.4	90.1	65.1	72.9
YOLOv6s	17.2	24	63.1	88.8	62.7	71.5
YOLOv7	36.9	40	71.5	88.9	73.8	78.1
YOLOv7-tiny	6.01	26	66.1	83.1	64.6	73.1
YOLOv8n	3.15	20	65.3	84.3	63.7	71.1
YOLOv8s	11.16	25	68.1	89.1	70.5	75.9
YOLOv8-FE	2.15	16	67.1	88.9	67.2	74.5
本文模型	2.15	16	68.0	89.2	68.1	75.4

从表 5 可以看出:本文提出的算法模型无论在参数量还是在推理速度上都是最少最快的,便于部署到一些计算资源相对有限的设备上,并且模型没有因为参数数量的下降和推理速度的变快导致其精度下降。在使用 BCKD 知识蒸馏之后,其模型精度达到 75.4%,只比效果最好的 YOLOv8s 低 0.5 个百分点,但是参数量比之 YOLOv8s 少了 80%,推理速度快了 36%。同样,对比其他轻量化模型如 YOLOv3-tiny、YOLOv7-tiny 和 YOLOv8n,其参数量分别下降了 82%、64% 和 26.7%,推理速度分别减少 27%、28% 和 20%,检测精度分别提高 19.5、2.3 和 4.3 个百分点。综上所述,相较于目前主流的目标检测算法,本文算法在安全帽佩戴检测上具有更快的检测速度和更高的检测精度。

为了更加直观看出来本文算法的有效性,使用 YOLOv8n 为基准模型和 YOLO-FE(BCKD)在数据集上进行可视化检测对比。其结果如图 9 所示。



图 9 YOLOv8n 和 YOLO-FE (BCKD) 检测可视化对比

Fig. 9 Visual comparison between YOLOv8n and YOLO-FE (BCKD) detection

从图 9 可以明显看出:原始 YOLOv8n 算法漏检率较高,检测精度一般;而本文提出的 YOLO-FE (BCKD)模型检测效果更好,更适合部署到现实变电所环境之中。

为了更好地验证本文提出算法适用于其他环境的安全帽佩戴检测,使用本文算法和其他主流目标检测算法在 GDUT-HWD 数据集上再次进行对比实验,实验结果如表 6 所示。

表 6 GDUT-HWD 数据集上对比结果

Table 6 Comparison results on the GDUT-HWD dataset

模 型	L _{mAP} /%	参数量/10 ⁶	推理速度/ms
SSD-PRA512 ^[18]	61.3	52.6	42.4
DS-YOLOv5 ^[19]	82.3	8.2	16
YOLOv3-tiny	60.2	12.1	32.3
YOLOv7-tiny	79.5	6.01	45
YOLOv8n	80.1	3.15	14
YOLOv8-FE(BCKD)	84.2	2.31	15

从表 6 看出:本文提出的算法模型在公开数据集上较之前的轻量化模型,有着较高的精度和检测速度,证明了本文模型在安全帽佩戴检测上具有一定的泛用性。

3 结论与展望

由于现阶段的安全帽佩戴检测算法存在检测精度和检测速度不平衡的问题,本文使用 YOLOv8n 作为基础进行改进,使用 FasterNet block 去替换原始网络中的 C2f 模块,大大减少了模型的参数量,加快了模型的检测速度;将 EMA 注意力机制加入主干网络里,能大大增强主干网络的特征提取能力,提高模型的检测精度;最后使用 BCKD 知识蒸馏对模型进行蒸馏处理,提高检测精度。通过消融实验和对比实验,证明本文算法的检测精度更高,检测速度更快,验证了本文算法的可行性,满足在变电所场景下安全帽佩戴检测的需求。

在今后的工作里,会继续探究在更加复杂场景下,如重叠目标等情况下的检测精度。

参考文献(References):

- [1] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.
- [2] GIRSHICK R. FastR-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2016: 1440-1448.
- [3] 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 Intelligence, 2017, 39(6): 1137-1149.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.
- [5] REDMON J, FARHADI A. Yolov3: An incremental improvement[C]//Proceedings of the IEEE Conference on Computer Vision Pattern Recognition. Piscataway: IEEE Press, 2018: 89-95.
- [6] WU T H, WANG T W, LIU Y Q. Real-time vehicle and distance detection based on improved YOLOV5 network[C]//Proceedings of the 3rd World Symposium on Artificial Intelligence. Piscataway: IEEE Press, 2021: 24-28.
- [7] YUNG N D T, WONG W K, JUWONO F H, et al. Safety helmet detection using deep learning: implementation and comparative study using YOLOv5, YOLOv6, and YOLOv7[C]//Proceedings of the International Conference on Green Energy, Computing and Sustainable Technology. Piscataway: IEEE Press, 2022: 164-170.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]// Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [9] 施辉, 陈先桥, 杨英. 改进 YOLO v3 的安全帽佩戴检测方法[J]. 计算机工程与应用, 2019, 55(11): 213-220. SHI Hui, CHEN Xian-qiao, YANG Ying. Safety helmet wearing detection method of improved YOLO v3[J]. Computer Engineering and Applications, 2019, 55(11): 213-220.
- [10] 金雨芳, 吴祥, 董辉, 等. 基于改进 YOLOv4 的安全帽佩戴检测算法[J]. 计算机科学, 2021, 48(11): 268-275. JIN Yu-fang, WU Xiang, DONG Hui, et al. Improved YOLOv4 algorithm for safety helmet wearing detection [J]. Computer Science, 2021, 48(11): 268-275.
- [11] 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 Yong-bo, LI Dong. Lightweight helmet wearing detection algorithm of improved YOLOv5[J]. Computer Engineering and Applications, 2022, 58(9): 201-207.
- [12] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 936-944.
- [13] NI Z L, BIAN G B, WANG G A, et al. Pyramid attention aggregation network for semantic segmentation of surgical instruments [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11782-11790.
- [14] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 8759-8768.
- [15] GU R, WANG G, SONG T, et al. CA-net: Comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2021, 40(2): 699-711.
- [16] WANG Q, WU B, ZHU P, et al. ECA-net: Efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 11531-11539.
- [17] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]//European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [18] WU J, CAI N, CHEN W, et al. Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset[J]. Automation in Construction, 2019, 106: 102894.
- [19] 白培瑞, 王瑞, 刘庆一, 等. DS-YOLOv5: 一种实时的安全帽佩戴检测与识别模型[J]. 工程科学学报, 2023, 45(12): 2108-2117. BAI Pei-rui, WANG Rui, LIU Qing-yi, et al. DS-YOLOv5: A real-time detection and recognition model for helmet wearing[J]. Chinese Journal of Engineering, 2023, 45(12): 2108-2117.

责任编辑:李翠薇