

文章编号:1671-6833(2025)03-0019-07

基于改进 YOLOv8n 的施工场景下防护装备佩戴检测算法

李 军, 周科宇, 邹 军, 曾文炳

(重庆交通大学 机电与车辆工程学院, 重庆 400074)

摘 要: 针对在施工场景中现有的防护装备检测算法存在受干扰信息影响、光照不均匀以及被作业设备遮挡等问题,提出了一种改进 YOLOv8n 的轻量化算法 YOLO-LA。首先,将加权双向特征金字塔网络 BiFPN 引入颈部,通过多路径交互融合,提高底层细节和高级语义信息,增强多尺度特征融合性能,提升模型对复杂场景小目标的检测精度;其次,在基线模型中使用 C2f-ContextGuided 模块对骨干网络进行改造,ContextGuided 模块使用全局上下文信息计算权重向量,并使用其细化局部特征和周围上下文特征的联合特征,从而提高模型的特征提取能力,并降低模型复杂度;再次,提出了一种全新的 LSCD 轻量化检测头,其使用共享卷积,减少模型的参数量和计算量;最后,用 EIoU 代替了原来的 CIoU,优化边框回归,提高了算法收敛速度和回归精度。实验结果表明:YOLO-LA 算法在防护装备佩戴检测中表现优异,相比基线模型 YOLOv8n,参数量、计算量和模型内存分别降低了 61.5%,43.2%和 58.7%,同时 $mAP@0.5$ 提升了 1.4 百分点,且 FPS 值为 253 帧/s,满足防护装备佩戴检测的实时性、准确性和轻量化要求。

关键词: 防护装备检测; BiFPN; LSCD; EIoU 损失; C2f-ContextGuided 模块; 模型轻量化

中图分类号: TP391.4

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2025.03.002

近年来,目标检测作为计算机视觉领域的基础任务之一,被广泛应用于各种工业场景中。王子豪等^[1]基于热力图预测减少了对“锚框”的依赖和计算,并将该改进用于对人物目标的位置检测。Gou 等^[2]针对目标激活区域设计增强模块,减少了环境背景对特征提取的干扰,增强了网络的特征学习能力,在安防领域的人体隐藏目标检测中取得显著成效。此外,还有用于公共交通的目标检测^[3]等。

目前对于防护装备佩戴检测方法主要是基于深度学习的目标检测方法,该方法基于候选区域的分类和基于端到端的回归^[4],即双阶段和单阶段两种目标检测算法。双阶段算法检测精度高而速度较慢,单阶段算法检测速度较快而检测精度较低,包括以 R-CNN^[5]、Faster R-CNN^[6]、Mask R-CNN^[7] 为代表的双阶段目标检测算法和以 YOLO 系列^[8-11] 为代表的单阶段目标检测算法。针对施工现场防护装备佩戴检测这种实时性和检测准确性要求较高并且能轻易部署在边缘设备上的场景,本文提出了一种改

进 YOLOv8n 的施工场景下防护装备佩戴检测模型,同时满足检测的实时性、准确性和轻量化要求。

在施工场景复杂环境背景下,有研究人员对 YOLO 算法进行改进,以满足特定条件下的检测要求。Zhou 等^[12]使用 YOLOv5 模型实现了建筑施工现场安全帽佩戴的高准确度、高速度检测。但由于数据集的真实场景较少,模型的泛化能力不强,Zeng 等^[13]改进了 YOLOv4 算法,改进后模型对建筑工地人员安全帽检测的精度和速度都有所提升,在特征金字塔中使用跨阶段层次模块代替多个卷积模块,提高模型检测小目标的性能。Cheng 等^[14]改进了轻量化 YOLOv3-Tiny 算法,用于人员安全帽佩戴检测,使用轻量级 Sandglass 残差模块替代原有的卷积层,减少了参数量。程焕新等^[15]提出了一种基于改进 YOLOX-S 算法的安全帽和反光衣检测方法,使用 Mosaic 方法进行训练,提高网络在复杂场景下的检测能力,通过引入 GIoU 损失函数,有效提高了模型的识别准确率。郑海洋等^[16]通过改进 YOLOv3

收稿日期:2024-11-19;修订日期:2024-12-20

基金项目:国家自然科学基金资助项目(51305472);重庆市研究生培养项目(JDLHPYJD2018003)

作者简介:李军(1964—),男,重庆人,重庆交通大学教授,博士,主要从事节能与新能源汽车、智能网联汽车的研究, E-mail: cqleejun@163.com。

引用本文:李军,周科宇,邹军,等. 基于改进 YOLOv8n 的施工场景下防护装备佩戴检测算法[J]. 郑州大学学报(工学版),2025,46(3):19-25,104. (LI J, ZHOU K Y, ZOU J, et al. Protective equipment wearing detection algorithm in construction scenarios based on YOLOv8n[J]. Journal of Zhengzhou University (Engineering Science), 2025,46(3): 19-25,104.)

时,仍然能够保持较少的参数量; $f_{\text{join}}(\cdot)$ 提取器将 $f_{\text{loc}}(\cdot)$ 和 $f_{\text{sur}}(\cdot)$ 的输出进行 Concat 操作,再通过 BN 层对模型训练进行加速收敛,Parametric ReLU 激活函数使得网络更具有稳健性,减少了对网络架构和超参数的敏感度,最终得到联合特征; $f_{\text{glo}}(\cdot)$ 提取器将联合特征进行全局平均池化和多层感知机操作,将得到的权重和输入按元素相乘得到最终的全局上下文特征。




图 3 ContextGuided 模块

Figure 3 ContextGuided module

使用 ContextGuided Block 改进 C2f 中的 Bottleneck 模块,得到新的 C2f-ContextGuided 模块如图 4 所示。该结构在不增加网络参数的情况下减小了模型的总体尺寸,利用空间依赖性和上下文信息,通过学习局部特征和上下文特征的联合特征,再利用全局上下文特征改进上述联合特征,能够更好地捕捉数据中的重要信息,减少冗余和无用信息的影响,增强网络的学习能力。




图 4 C2f-ContextGuided 模块

Figure 4 C2f-ContextGuided module

2.3 LSCD 轻量化检测头

YOLOv8n 采用解耦头,将检测头分为两个分支,每个分支都会进行两个 $3 \times 3 \text{Conv}$ 操作和一个 $1 \times 1 \text{Conv2d}$ 操作,这会产生冗余的参数计算量且模型检测精度会受影响。由于施工场景下防护装备佩戴检测对实时性要求高,因此重新设计检测头,整体结构如图 5 所示。

设计 Conv_GN 模块,其结构如图 6 所示,将 CBS 模块中的 BN (batch normalization) 层修改为 GN^[21] (group normalization) 层。这是因为 BN 层在 *batchsize* 过小时性能降低,过大时容易显存不足,而 GN 将有关联的特征通道分为一组,并计算通道方向每个 group 的均值和方差,在每个 group 内进行归一化,灵活避开了 BN 的问题,同时提升了检测头定位和分类性能。此外,在检测头部分还使用了共享卷积操作,通过 $1 \times 1 \text{Conv_GN}$ 模块的输出数据输入到 $3 \times 3 \text{Conv_GN}$ 模块,在输入数据的每个位置,都使

用相同的卷积核进行卷积操作。这种共享参数的方式可以有效提取输入数据的特征,降低模型的复杂度。为了应对每个检测头所检测的目标尺度不一致的问题,通过 Scale 层对特征进行缩放。

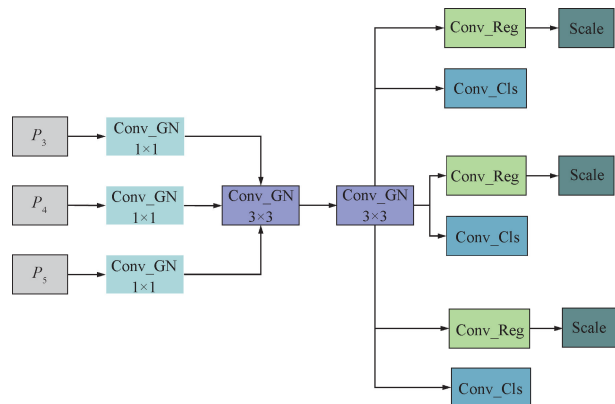


图 5 LSCD 轻量化检测头

Figure 5 LSCD lightweight detection head



图 6 Conv_GN 结构图

Figure 6 Structure diagram of Conv_GN

2.4 优化边界框损失函数

损失函数通常用于模型的训练和优化, YOLOv8n 采用的是 CIoU 损失函数^[22],表达式为

$$\begin{cases} \text{CIoU} = \text{IoU} - \left(\frac{\rho^2(b, b^{\text{gt}})}{C^2} + \alpha v \right); \\ v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2; \\ \alpha = \frac{v}{(1 - \text{IoU}) + v}; \\ L_{\text{CIoU}} = 1 - \text{CIoU}. \end{cases} \quad (1)$$

式中:IoU 为两框之间的交并比; ρ 为两个框中心点之间的距离; α 为权衡参数; v 为衡量长宽比一致性的参数; w^{gt} 、 h^{gt} 分别为目标框的宽和高; w 、 h 分别为预测框的宽和高。

然而,CIoU 损失函数存在宽高比例不明确的问题,可能导致宽度和高度差异被忽略。因此使用 EIoU 损失函数可以更全面地评估边界框预测的准确性,进一步提高模型的性能。该损失函数的表达式如下:

$$L_{\text{EIoU}} = 1 - \text{EIoU} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{C^2} + \frac{\rho^2(w, w^{\text{gt}})}{C_w^2} + \frac{\rho^2(h, h^{\text{gt}})}{C_h^2}. \quad (2)$$

式中: C 为预测框和目标框的最小外接框的对角线距离; C_w 和 C_h 分别表示预测框和目标框的最小外接框宽度和高度; $\rho^2(b, b^{\text{gt}})$ 表示预测框和目标框中心

型内存,使得模型更加轻量化。

表 2 C2f-ContextGuided 模块不同位置对比

Table 2 Comparison of different positions of the C2f-ContextGuided module				
模型	<i>mAP@</i>	参数	计算量/	模型内
	0.5	量/MB	GFLOPs	存/MB
YOLOv8n	0.878	3.01	8.1	6.3
C2f-ContextGuided-all	0.870	2.10	5.8	4.5
C2f-ContextGuided-neck	0.865	2.57	7.2	5.4
C2f-ContextGuided-backbone	0.879	2.54	6.7	5.3

3.5 损失函数有效性

为了验证 EIoU 损失函数的有效性,在原模型 YOLO8n 的基础上将 EIoU 损失函数分别与 GIoU、WIoUv3、SIoU、DIoU、inner-EIoU 损失函数进行对比,结果如表 3 所示。由表 3 可知,使用 EIoU 模型的性能最好。EIoU 提高了模型高质量 anchor 的贡献,有效减少了模型训练的回归定位损失。

表 3 损失函数对比

Table 3 Comparison of loss functions					
损失函数	<i>AP</i>				<i>mAP@</i> 0.5
	Human	Glove	Helmet	SafetyVest	
CIoU	0.898	0.771	0.867	0.977	0.878
GIoU	0.861	0.775	0.859	0.965	0.865
WIoUv3	0.871	0.788	0.874	0.975	0.877
SIoU	0.859	0.769	0.866	0.981	0.869
DIoU	0.879	0.769	0.870	0.981	0.875
inner-EIoU	0.899	0.796	0.853	0.981	0.882
EIoU	0.895	0.794	0.871	0.983	0.886

3.6 消融实验

为验证每个改进模块对基线模型的优化效果,本文共进行了 10 组消融实验,在 3.1 节所述的相同实验环境和参数配置下进行实验,每组消

融实验的 *epoch* 都设置为 200,在验证集上对各个训练输出的最佳权重文件进行验证,得到数据如表 4 所示。

在基线模型上引入 C2f-ContextGuided 模块、LSCD 轻量化检测头、BiFPN 结构以及 EIoU 损失函数,改进后模型所拥有的参数量、计算量、模型内存都有明显缩减,同时检测精度和 *FPS* 也显著提升。为进一步优化模型算法,将改进模块两两组合进行消融实验,其中将 BiFPN 结构和 C2f-ContextGuided 模块进行结构改进,得到的参数量、计算量和模型内存分别为 1.16 MB、4.6 GFLOPs 和 2.6 MB,同时 *mAP@* 0.5 达到 88.3%,在此基础上依次引入 LSCD 轻量化检测头和 EIoU 损失函数,得到最终的改进模型 YOLO-LA,相较于基线模型,参数量、计算量和模型复杂度分别降低了 61.5%、43.2% 和 58.7%,*mAP@* 0.5 提高了 1.4 百分点,*FPS* 为 253 帧/s,证明了本文所提算法的实时性和有效性。

3.7 不同算法性能对比

为验证本文算法 YOLO-LA 的优越性,将改进算法 YOLO-LA 与一系列当前热门的 YOLO 算法在同一环境下进行对比实验,实验结果如表 5 所示。

由表 5 可知,本文改进算法不仅参数量、模型内存及计算量小于其他对比网络,而且 *mAP@* 0.5 的值明显大于其他网络。因此改进模型算法在各个指标方面都展现了明显的优越性。

3.8 算法效果验证

为了验证改进模型在实际检测中的效果,将 YOLOv8n 和 YOLO-LA 算法在各种复杂场景下的防护装备佩戴检测结果进行可视化图片对比,如图 9 所示。

表 4 消融实验结果

Table 4 Results of ablation experiments												
BiFPN	C2f-Context-Guided	LSCD	EIoU	AP				$mAP@0.5$	参数	计算量/	模型内	FPS/
				Human	Glove	Helmet	SafetyVest		量/MB	GFLOPs	存/MB	(帧·s ⁻¹)
✓	✓	✓	✓	0.898	0.771	0.867	0.977	0.878	3.01	8.1	6.3	212
				0.899	0.803	0.837	0.978	0.879	1.99	7.1	4.2	227
0.907				0.784	0.846	0.980	0.879	2.54	6.7	5.3	245	
0.914				0.796	0.877	0.974	0.890	2.36	6.5	4.9	258	
✓	✓	✓	✓	0.895	0.794	0.871	0.983	0.886	3.01	8.1	6.3	220
				0.886	0.783	0.886	0.973	0.877	1.63	6.0	3.5	242
0.895				0.783	0.865	0.968	0.878	1.90	5.2	4.0	265	
0.889				0.785	0.877	0.980	0.883	1.16	4.6	2.6	247	
✓	✓	✓	✓	0.889	0.785	0.880	0.980	0.884	1.16	4.6	2.6	255
✓	✓	✓		0.885	0.816	0.884	0.984	0.892	1.16	4.6	2.6	253

注:✓表示采用该改进算法。

表 5 不同算法对比实验结果

Table 5 Comparison among experimental results of different algorithms

模型	AP				mAP@ 0.5	参数量/MB	计算量/ GFLOPs	模型内存/ MB
	Human	Glove	Helmet	SafetyVest				
YOLOv3-tiny	0.784	0.736	0.781	0.956	0.814	12.13	18.9	24.4
YOLOv5s	0.872	0.820	0.856	0.987	0.884	7.02	15.8	14.5
YOLOv6	0.883	0.767	0.854	0.975	0.870	4.23	11.8	8.7
YOLOv7-tiny	0.861	0.802	0.865	0.988	0.879	6.01	13.1	12.3
YOLOv8n	0.898	0.771	0.867	0.977	0.878	3.01	8.1	6.3
YOLOv8s	0.883	0.797	0.888	0.982	0.888	11.10	28.4	22.5
YOLO-LA	0.885	0.816	0.884	0.984	0.892	1.16	4.6	2.6




图 9 防护装备佩戴检测效果对比图

Figure 9 Comparison of the detection effect of protective equipment wearing

由图 9 可以看出,在遮挡环境下,造成待测目标仅保留局部特征,使得网络提取到的特征不全,导致左图反光衣漏检,改进 C2f-ContextGuided 通过融合局部特征和全局特征强化对目标的关注度,提升网络对该类目标的特征提取能力,解决了漏检的问题,如图 9 中右图所示检测出了所有目标,同时使用 BiFPN 多尺度融合机制提高了对小目标(安全手套)的检测精度。

在夜晚环境下,光线较暗,导致目标物体不易辨别和定位,同时背景干扰较大,容易产生误判,此外,夜晚环境下目标物体的形状、颜色和纹理等特征也变得模糊不清,增加了目标检测的难度,通过改进检测头,在 LSCD 检测头中采用共享卷积操作可以帮助模型在夜晚学习到更加通用的特征表示,从而实现更好的性能表现。

在光线不均环境下,能见度和清晰度显著降低,

模型特征学习变得更加困难,导致图 9 中左图安全帽检测精度较低,通过改进损失函数,解决了 CIoU 无法准确反映宽、高与置信度之间真实差异的问题,同时提高了目标检测任务的准确性,缓解了上述现象,因此图 9 中右图检测效果显著优于左图。

综上,本文模型对漏检、精度低等问题有明显改善,进一步证明了本文模型的有效性和实用性。

4 结论

针对在施工场景中现有的防护装备检测算法存在受复杂背景干扰、光照昏暗不均以及被施工设备遮挡等问题,本文提出的 YOLO-LA 算法表现较好,平均精确度为 89.2%,检测速度为 253 帧/s,相比基线模型 YOLOv8n,参数量、计算量和模型内存分别降低了 61.5%,43.2%和 58.7%,检测识别和轻量化效果都有所提高。

(1) BiFPN 增强了模型的多尺度特征融合能力,提高了对小目标的检测能力。

(2) C2f-ContextGuided 模块提高了模型对局部特征和上下文特征的联合使用,能够更好地捕捉图像中的重要信息,降低了模型计算复杂性、网络结构复杂性并增强了网络灵活性。

(3) LSCD 轻量化检测头使用组归一化(GN)和共享卷积提高了检测头定位和分类性能,并降低了模型的复杂度。EIoU 损失函数有效提高了模型 anchor 的质量,改善了目标检测的准确度、稳定性和自适应能力。

下一步工作将研究基于 YOLOv8 改进算法的智慧工地防护装备佩戴检测的实际应用,以智慧工地管理系统的方式代替人工巡检的自主目视检测。

参考文献:

[1] 王子豪,方成,李丽萍,等. 基于热力图预测的免“锚框”人物目标检测算法[J]. 计算机工程, 2024, 50 (10):51-60.

- WANG Z H, FANG C, LI L P, et al. Anchor-free person target detection algorithm based on heat map prediction [J]. Computer Engineering, 2024, 50(10): 51–60.
- [2] GOU S P, WANG X L, MAO S S, et al. Weakly-supervised semantic feature refinement network for MMW concealed object detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(3): 1363–1373.
- [3] CAO J, LI P H, ZHANG H, et al. An improved YOLOv4 lightweight traffic sign detection algorithm [J]. IAENG International Journal of Computer Science, 2023, 50(3): 825–831.
- [4] 许德刚, 王露, 李凡. 深度学习的典型目标检测算法研究综述[J]. 计算机工程与应用, 2021, 57(8): 10–25.
- XU D G, WANG L, LI F. Review of typical object detection algorithms for deep learning [J]. Computer Engineering and Applications, 2021, 57(8): 10–25.
- [5] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 580–587.
- [6] REN S Q, HE K M, 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.
- [7] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C] // 2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 2980–2988.
- [8] ROY A M, BOSE R, BHADURI J. A fast accurate fine-grain object detection model based on YOLOv4 deep neural network [J]. Neural Computing and Applications, 2022, 34(5): 3895–3921.
- [9] QIAO S Y, CHEN L C, YUILLE A. DetectoRS: detecting objects with recursive feature pyramid and switchable atrous convolution [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 10213–10224.
- [10] BIST R, SUBEDIS B, YANG X, et al. A novel YOLOv6 object detector for monitoring piling behavior of cage-free laying hens [J]. Agriengineering, 2023, 5(2): 905–923.
- [11] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 7464–7475.
- [12] ZHOU F B, ZHAO H L, NIE Z. Safety helmet detection based on YOLOv5 [C] // 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA). Piscataway: IEEE, 2021: 6–11.
- [13] ZENG L P, DUAN X L, PAN Y H, et al. Research on the algorithm of helmet-wearing detection based on the optimized yolov4 [J]. The Visual Computer: International Journal of Computer Graphics, 2023, 39(5): 2165–2175.
- [14] CHENG R, HE X W, ZHENG Z L, et al. Multi-scale safety helmet detection based on SAS-YOLOv3-tiny [J]. Applied Sciences, 2021, 11(8): 3652.
- [15] 程换新, 蒋泽芹, 程力, 等. 基于改进YOLOX-S的安全帽反光衣检测算法[J]. 电子测量技术, 2022, 45(6): 130–135.
- CHENG H X, JIANG Z Q, CHENG L, et al. Helmet and reflective clothing detection algorithm based on improved YOLOX-S [J]. Electronic Measurement Technology, 2022, 45(6): 130–135.
- [16] 郑海洋, 宋纯贺, 武婷婷, 等. 面向绝缘手套佩戴状况检测的小目标检测与匹配算法[J]. 小型微型计算机系统, 2023, 44(9): 1989–1995.
- ZHENG H Y, SONG C H, WU T T, et al. Small target detection and matching algorithm for wearing condition detection of insulating gloves [J]. Journal of Chinese Computer Systems, 2023, 44(9): 1989–1995.
- [17] TAN M X, PANG R M, LEQ V. EfficientDet: scalable and efficient object detection [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 10781–10790.
- [18] ZHANG Y F, REN W Q, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146–157.
- [19] GHIASI G, LIN T Y, LE Q V. NAS-FPN: learning scalable feature pyramid architecture for object detection [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 7036–7045.
- [20] WU T Y, TANG S, ZHANG R, et al. CGNet: a lightweight context guided network for semantic segmentation [J]. IEEE Transactions on Image Processing, 2021, 30: 1169–1179.
- [21] WU Y X, HE K M. Group normalization [J]. International Journal of Computer Vision, 2020, 128(3): 742–755.
- [22] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: faster and better learning for bounding box regression [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993–13000.