

基于 YOLOv5s 的安全帽识别研究

王 冲¹ 姚有利¹

WANG Chong YAO Youli

摘 要

在煤矿和建筑等行业生产作业中,由于工作人员未正确佩戴安全帽而导致的安全事故不在少数,传统的人工检查方式存在诸多不足,为提高检测准度和效率,文章提出了一种基于 YOLOv5s 的改进算法模型。首先对 YOLOv5s 模型进行改进,通过添加小目标检测层来提高算法对小目标的检测;然后使用 Focal-EIoU 损失函数来替代 CIoU 提高目标检测模型的精度;最后在数据集进行训练,训练结果显示:改进后的算法 mAP@0.5 达到了 88.3%,在原始算法 86.1% 的基础上提高了 2.2%。改进后的检测算法为安全帽智能识别奠定理论基础。

关键词

YOLOv5s; 深度学习; Focal-EIoU; 小目标检测层; 安全帽

doi: 10.3969/j.issn.1672-9528.2025.04.039

0 引言

安全帽是保护工作人员的一道重要防护^[1],但在煤矿和建筑等行业生产作业中,容易出现安全帽脱落的情况。传统检查是否正确佩戴安全帽的方式为人工检查^[2],这种方式不仅效率不高,而且会出现漏检错检的情况,极为不便和不安全。近年来,随着视频监控系统的广泛应用,基于深度学习的目标检测技术得到了快速发展^[3]。与传统的肉眼检查工人是否佩戴安全帽相比,目标检测算法在确保准确性的同时,不仅操作高效迅捷,还能减轻人力压力,降低企业生产成本,对施工作业有着重要的安全意义。

传统的图像检测方法依赖于手工设计被检测对象的特征^[4-6],这种方法通常需要提取大量的特征样本才能实现对象的安全帽佩戴的准确识别,导致了时间较长和人力成本较高,同时也存在算法鲁棒性差,难以在实际场景中应用的问题。随着基于区域的卷积神经网络(region-based convolutional neural network, RCNN)^[7]的提出,深度学习方法的检测效果明显优于传统方法,因此基于深度学习的检测技术逐渐成为主流。随后,以 YOLOv1^[8](you only look once, version 1)为代表的单阶段目标检测方法^[9]的应运而生,使得 YOLO 系列在目标检测领域得到了广泛应用。例如,朱栋等人^[10]利用 YOLO 系列进行太阳能电池板缺陷检测的研究。于秋波等人^[11]通过引入 SimAM 注意力机制同时使用 SPPFCSPC 方法来减少参量,使得 mAP@0.5 提升了 6.7%。李天宇等人^[12]引入 scSE 注意力机制同时利用 Kmeans++ 算法对安全帽数据

进行 anchor 尺寸优化,使得 SR_YOLO 的 mAP 为 84.05%。邱云飞等人^[13]提出了一种基于 YOLOv8 的 HD-YOLO 安全帽佩戴检测算法,有效解决了由于复杂施工场景带来的漏检等问题。孙光灵等人^[14]用 Wise-IoU 损失函数来平衡不同质量的锚框减少漏检,并使平均精度值提升 3.5%,参数量减少 18.1%,浮点运算数减少 1.8%。程磊等人^[15]基于 YOLOv8 提出 1 种改进的目标检测算法 SMT-YOLOv8s,该算法相较于 YOLOv8s 模型在自建数据集上的 mAP50 和 mAP50~95 分别提高 3.7 个百分点和 2.7 百分点。

在当前众多目标检测算法中,YOLOv5s 以轻量化且高准确度等优势应用较为广泛。但是考虑到施工现场或者井下环境复杂会导致目标检测算法在检测中受到影响。本文在原本 YOLOv5s 的模型基础上使用 Focal-EIoU 损失函数来精确边界框回归。添加一层小目标检测层来用于提高针对安全帽的检测。

1 YOLOv5s 算法

1.1 YOLO 简介

YOLO(you only look once)是一种用于实时目标检测的算法。通过单一的卷积神经网络(CNN)将目标检测任务视为一个回归问题,从输入图像中直接预测边界框和各类别的概率。该算法运用深度学习的回归方法,实现了端到端的目标检测,满足实时应用的需求。从 2015 年,Joseph Redmon 提出 YOLOv1 以来,到 2020 年,算法已发展到 YOLOv4。与之前的版本相比,YOLOv5 采用了更轻量级的网络结构,并引入了多种优化技术,如 PReLU 激活函数和跨阶段部分网络等。YOLOv5 在保证准确性的同时,进一步提升了检测速度。近年来,YOLO 系列迅速推出了 YOLOv6、YOLOv7、

1. 山西大同大学煤炭工程学院 山西大同 037003
[基金项目]山西大同大学研究生实践创新类项目(2024SJCX14)

YOLOv8 和 YOLOv9, 以及最新推出的 YOLOv11 新模型。但在基本结构上并没有进行重大改动。总体来看, YOLO 系列算法通过持续地优化和创新, 在目标检测领域取得了显著成就。成熟的 YOLOv5 系列已经在多个工业领域得到广泛应用, 并具备轻量化的优势。自发布以来, YOLOv5 模型经历了持续的更新和迭代, 导致不同版本之间的网络结构存在一定差异。目前, 官方已经推出了四种不同规模的模型, 包括 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。考虑到煤矿井下环境以及施工场景的复杂性, 本文选择了相对轻量化且易于使用的 YOLOv5s 模型进行数据集的训练。

1.2 YOLOv5s 简介

YOLOv5s 是一种轻量级的目标检测算法, 基于卷积神经网络 (CNN), 可分为 3 个主要部分: backbone、Neck 和 head。backbone (主干网络) 利用一系列卷积层和池化层对输入图像进行处理, 逐步减小特征图的尺寸, 同时增加通道数。这样做的目的是保留和提取图像中的重要特征。经过 backbone 提取的特征图会传递给后续的特征金字塔网络 (neck) 和检测头 (detection head) 进行处理。Neck 主要负责对这些特征进行进一步的加工, 并生成最终的输出结果。Neck 作为连接 backbone 和 detect 的网络模块, 起到了关键的作用。在主干网络提取的特征基础上, 进行特征融合和上采样操作, 以增强高级语义信息并适应不同尺度的图像。Head 部分则对提取到的特征进行进一步处理, 并生成最终的输出结果。原 YOLOv5s 网络结构如图 1 所示。




图 1 原 YOLOv5s 的网络结构图

2 改进 YOLOv5s 模型

2.1 添加小目标检测层

在实际工作场景中, 工人可能分散在不同的距离和角落,

这导致他们佩戴的安全帽在图像中显示出各种尺寸差异。特别是在含有多个安全帽的图像中, 这种差异尤为明显。为了解决这一问题, 本文在原有 YOLOv5s 模型的 P3、P4 和 P5 三个检测头的基础上, 新增了一个微小物体检测头 P2, 它具有更高分辨率的 $160 \text{ px} \times 160 \text{ px}$ 特征图。由于 P2 层位于网络的较浅层, 能够更准确地捕捉小目标的细节信息, 从而提升了对小目标 (如安全帽) 的检测能力。添加小目标检测层后的网络结构如图 2 所示。




图 2 改进后 YOLOv5s 的网络结构图

2.2 损失函数改进

YOLOv5s 采用的是 CIoU 损失函数, 但是 CIoU 损失函数仅考虑了目标框之间的重叠程度和尺寸差异, 未考虑边界框的形状差异, 在处理不同尺度的目标, 尤其是小目标时, 会受到尺寸变化的影响, 导致检测精度下降, 考虑此种原因, 本文采用了 Focal-EIoU 损失函数 (focal and efficient intersection over union loss), 如式 (2) 所示, 该损失函数平衡高质量样本和低质量样本对 loss 的贡献, 也就是提升高质量 (IoU 大) 样本的贡献, 抑制低质量 (IoU 小) 样本的贡献。

$$\text{EIoU}_{\text{Loss}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{(\omega^c)^2 + (h^c)^2} + \frac{\rho^2(\omega, \omega^{\text{gt}})}{(\omega^c)^2} + \frac{\rho^2(h, h^{\text{gt}})}{(\omega^c)^2} \quad (1)$$

$$\text{Focal - EIoU}_{\text{Loss}} = \text{IoU}^\gamma \text{EIoU}_{\text{Loss}} \quad (2)$$

式中: IoU 是预测边界框和地面实况边界框的相交面积与并集面积的比值; $B^{\text{gt}} = (x^{\text{gt}}, y^{\text{gt}}, w^{\text{gt}}, h^{\text{gt}})$ 是地面实况边界框; $B = (x, y, w, h)$ 是预测边界框; x 、 y 分别是边界框中心点的坐标; h 分别是宽和高; b 和 b^{gt} 分别是预测框和真实框的中心点; ρ 是计算两个中心点之间的欧氏距离; c 表示能够同时包含预测框和真实框的最小闭包区域的对角线距离。

3 实验

3.1 数据集

该实验的训练过程在 Windows10 系统下，通过 PyCharm 集成开发环境中进行。硬件配置分别为：CPU 为 Intel Core i5-9300H，GPU 为 AutoDL 平台中租赁的 NVIDIA GeForce RTX 3090。开发环境为 CUDA-11.3，Python 版本为 3.8。训练次数 epochs 为 100。本文所使用的数据集包含 6 421 张图片，涵盖了井下员工佩戴安全帽的情况和地面施工人员的工作图片。该数据集按照 8:1:1 的比例划分为训练集、验证集和测试集。

3.2 评价指标

本文实验通过精确率 P (precision)、平均均值精度 mAP (mean average precision) 以及召回率 R (recall) 来评估改进后的 YOLOv5s 网络在井下安全帽佩戴检测中的效果。其中，精确率 P 表示预测为正样本中实际正样本的比例，其计算公式为：

$$P = \frac{TP}{TP + FP} \quad (3)$$

通过对所有类别的平均精度 AP (average precision) 值取平均，可以得到 mAP 值 (mean average precision)，用于衡量检测任务中待测数据集中所有类别的检测结果。其计算公式为：

$$mAP = \sum_{i=1}^N AP_i \quad (4)$$

式中： N 为样本的类别总数； P 为精确率，本文默认在 IoU 阈值为 0.45 的情况下进行精度计算，即 AP@0.45 和 mAP@0.45。召回率的计算式为：


$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (5)$$

式中： N_{TP} 为真正例，即井下安全帽图像被正确检测的图像数量； N_{FN} 为假负例，即井下安全帽图像被漏检的数量。


3.3 实验结果对比

观察损失曲线可知，边界框损失维持在 0.03 左右，置信度损失值稳定在 0.007 左右。经过 90 次迭代，分类损失趋近于 0。根据四个性能度量指标的收敛曲线可知，本文提出的模型在各项指标上表现出迅速的收敛速度，最终达到的 mAP@0.5 为 88.3%，准确率接近 89%，召回率达到 83.2%。

为了探究本文算法对数据集中佩戴安全帽和未佩戴安全帽两种目标检测的具体提升情况，采用本文算法与原 YOLOv5s 模型进行实验对比。这两种算法在测试集上的 P - R 曲线如图 3 所示。图中 (a) (b) 中的曲线从左到右分别代表 no-helmet、all classes 和 helmet 的三种训练效果曲线。



(a) 原 YOLOv5 模型



(b) 本文算法模型

图 3 不同模型在测试集上的 P-R 曲线图

P - R 曲线与坐标轴围成的面积越大，AP 值越高，模型性能越好。从图 3 可以看出，本文算法对应的 P - R 曲线所围成的面积大于原始 YOLOv5s 模型，由此可得本文算法在测试集中检测精确率高于原 YOLOv5s 模型。表 1 对比了 YOLOv5s 和本文算法在测试集上的性能评估指标。综合检测佩戴安全帽和未佩戴安全帽两类目标的结果显示，本文算法相较于原始 YOLOv5s 算法，平均精度 mAP@0.5% 提升了 2.2%。由表 2 可知，改进损失函数后使得精度提升了 1.2%，再添加小目标检测层后使得精度提升了 2.2%。


表 1 本文算法与 YOLOv5s 检测性能对比

算法	class	$P/\%$	$R/\%$	mAP@0.5%
YOLOv5s	helmet	91.4	84.8	90.1
	no-helmet	89	76.2	82.1
	all	90.3	80.7	86.1
本文算法	helmet	89.5	83.2	89.4
	no-helmet	88.6	81.9	87.2
	all	89	83.2	88.3

表 2 消融实验结果

优化策略		评价指标		
Focal-EIoU	小目标检测层	$P/\%$	$R/\%$	mAP@0.5%
		90.3	80.7	86.1
✓		90.9	81.1	87.3
✓	✓	89.1	82.1	88.3

为直观地比较改进后的 YOLOv5s 模型在矿井安全帽检测任务中的效果,针对原始算法 (a) 和本文算法 (b) 进行实验对比。图 4 为改进后算法的检测结果对比图。



(a) 原始算法



(b) 本文算法

图 4 算法检测效果图

4 结论

(1) 针对煤矿井下和建筑施工复杂环境导致目标检测算法精度低和漏检率高等问题,本文在 YOLOv5s 网络模型中添加了小目标检测层,来提高安全帽检测的精度,同时使用 Focal-EIoU 损失函数来解决图像尺寸变化的问题。

(2) 根据实验结果表明,本文算法平均检测精度 mAP@0.5 可达 88.3%,在原始算法 86.1% 的基础上提高了 2.2%。

(3) 本文算法与 YOLOv5s 进行对比实验,结果表明本文算法各项性能优于原模型,在复杂井下环境中能够有效缓解漏检、误检现象。在理论上为安全帽的智能识别研究奠定了基础。

参考文献:

- [1] 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[2024-11-14].<http://kns.cnki.net/kcms/detail/11.2402.TD.20240322.1607.005.html>.
- [2] 张国鹏,周金治,马光岑,等.改进 YOLOv8 的轻量化安全帽佩戴检测算法[J].电子测量技术,2024,47(17):147-154.
- [3] 李雯静,刘鑫.基于深度学习的井下人员不安全行为识别与预警系统研究[J].金属矿山,2023(3):177-184.
- [4] RUBAIYAT A H M,TOMA T T,KALANTARI-KHANDANI M, et al. Automatic detection of helmet uses for construction safety[C]//2016 IEEE/WIC/ACM International Conference on Web Intelligence Workshops (WIW).Piscataway:IEEE,2016:135-142.
- [5] 贾峻苏,鲍庆洁,唐慧明.基于可变形部件模型的安全头

盔佩戴检测[J].计算机应用研究,2016,33(3):953-956.

- [6] FANG L J, LIN T W, WU J, et al. A DPM based approach to joint object detection and sub-category recognition[C]// 2017 IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER). Piscataway: IEEE, 2017:164-168.
- [7] 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.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016:779-788.
- [9] 张阳婷,黄德启,王东伟,等.基于深度学习的目标检测算法研究与应用综述[J].计算机工程与应用,2023,59(18):1-13.
- [10] 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.
- [11] 于秋波,万擎,胡文字,等.基于改进型 YOLOv5s 的安全帽检测[J].微处理机,2023,44(6):50-54.
- [12] 李天宇,吴浩,毛艳玲,等.改进 YOLOv4 的安全帽佩戴检测方法[J].计算机工程与设计,2023,44(8):2374-2381.
- [13] 邱云飞,腰瑞琳,金海波,等.HD-YOLO:复杂场景下安全帽佩戴检测算法[J].安全与环境学报,2025,25(1):165-174.
- [14] 孙光灵,黄磊,吴倩.基于 KD-YOLO 的轻量化安全帽佩戴检测方法[J].淮北师范大学学报(自然科学版),2024,45(2):41-48.
- [15] 程磊,张俊展,景国勋,等.基于 YOLOv8 的煤矿安全帽和安全背心检测算法[J].中国安全生产科学技术,2025,21(2):115-121.

【作者简介】

王冲(2000—),男,河南驻马店人,硕士研究生,研究方向:基于深度学习的不安全行为识别。

姚有利(1974—),女,内蒙古商都人,博士,教授,研究方向:安全工程。

(收稿日期:2025-03-12)