

基于 YOLOv11 的井下人员不安全行为识别方法研究

蒋东升^{1,2}, 朱权洁^{1,2*}, 郝英楠^{1,2}, 陈昱翔^{1,2}

(1. 华北科技学院应急技术与管理学院; 2. 防灾科技学院文化与传播学院)

摘要: 井下工作环境复杂, 安全隐患众多, 而传统监管方式局限性大且难以做到全方位实时监管, 因此基于机器学习的井下人员不安全行为识别研究迫在眉睫。提出一种基于 YOLOv11 的井下人员不安全行为识别方法和模型。将人员不安全行为划分为物品防护类、危险区域类和危险行为类 3 种; 然后, 根据行为划分组建数据集, 并使用 Albumentations 进行数据增强, 通过光线亮度调节, 增加噪声等方式模拟井下环境变化以提升模型的泛化性和鲁棒性; 使用一种半自动标注的方式进行数据标注, 并对模型进行训练。结果表明: 经过 Albumentations 进行数据增强, 同时使用半自动标注的方法, 在不需要大量人工标注的情况下可获得较好识别效果。

关键词: YOLOv11; 不安全行为; 行为识别; 数据增强; Albumentations; 半自动标注

中图分类号: TD76

文献标志码: A

文章编号: 1001-1277(2025)07-0032-04

doi: 10.11792/hj20250704

引 言

非煤矿山开采主要分为露天开采与地下开采 2 种方式。相较于露天开采, 地下开采作业环境复杂, 人员与设备众多, 存在安全隐患^[1]。从安全事故发生原因分析, 人的不安全行为和物的不安全状态是事故发生的主要原因^[2-3]。相较于物的不安全状态, 人的因素在地下开采环境中更为复杂^[4]。地下开采作业不仅要求工人具备专业知识与技能, 如掌握地质构造知识、熟悉开采设备操作等, 而且还需要工人在作业过程中保持专注。然而, 井下工作环境具有特殊性, 如工作空间狭窄、光线昏暗等, 且存在诸如冲击地压等危险因素, 人长期处于此环境下, 承受较大心理压力, 并且工作强度大, 极易出现疲劳、注意力不集中等情况, 从而做出危险行为, 进而导致事故的发生, 甚至造成严重的人员伤亡^[5-8]。

目前, 针对非煤矿山地下开采人员不安全行为的监控与识别, 主要依靠人工巡检和监控视频回放^[9]。由于井下作业区域广泛, 巡查存在局限性, 难以实现全方位、实时监控。监控视频回放, 不仅效率低, 而且由于人主观性的存在, 不同人员有不同判断标准, 影响判断结果。此外, 视频监控回放多为事后监督, 在不安全行为发生时难以及时发现并处理。随着深度学习和机器视觉技术的飞速发展^[10-13], 对井下人员不

安全行为识别的研究也取得了相当大的进展, 这为井下安全管理提供了新的途径^[14-17]。深度学习具有强大特征提取与模式识别能力, 能从大量数据中挖掘潜在规律; 计算机视觉算法基于深度学习, 可对图像或视频中的目标进行识别、跟踪与分析^[18-20]。将二者结合起来, 针对井下发生的人员不安全行为这一背景和需求, 对人员不安全行为进行分类, 并构建基于 YOLOv11 算法的识别模型, 实现不安全行为的识别和预警。

1 数据集构建

1.1 不安全行为定义与分类

目前, 不安全行为的界定较为宽泛, 并且由于行业不同, 界定侧重点也不同, 但总体来看, 不安全行为可确定为在生产过程中, 人的因素可能导致事故发生的行为。因此, 本文将井下人员不安全行为定义为“井下人员在生产中违反相关规定或安全常识做出可能导致事故发生或加重事故后果的行为”, 并结合井下环境和人员的特殊性和多样性, 将不安全行为分为三类: 物品防护类、危险行为类和危险区域类。具体描述如表 1 所示。

1.2 数据准备

在计算机视觉的目标检测任务中, 训练数据的质量直接关系到模型最终性能。根据对不安全行为的分类,

收稿日期: 2025-03-19; 修回日期: 2025-04-08

基金项目: 中央高校基本科研业务费项目(3142021002); 廊坊市科技支撑计划项目(2024013001); 华北科技学院校级教育科学研究课题(HKJYZX202401); 2023 年度河北省高校创新创业教育教学改革研究与实践项目

作者简介: 蒋东升(2000—), 男, 硕士研究生, 研究方向为矿山灾害监测预警; E-mail: jiang18355083580@163.com

*通信作者: 朱权洁(1984—), 男, 教授, 博士, 从事煤岩动力灾害监测预警与防控、数字化矿山、防灾减灾等方面的科研工作; E-mail: zhqj2016@ncist.edu.cn

表 1 不安全行为定义及后果
Table 1 Definitions and consequences of unsafe behaviors

分类	定义	后果
物品防护类	物品存储不当或未按规定穿戴防护装备	增加事故发生后损伤程度
危险行为类	违反规章制度或安全常识违规操作	增加事故发生的可能性
危险区域类	未经授权闯入危险区域或非工作场所	增加事故发生的可能性和损伤程度

数据选取公开的矿井场景数据,包括不同矿井和不同作业阶段的图片与视频数据。同时,由于当前井下不安全行为识别研究尚处于发展阶段,此类数据集数据较为稀少,所以采取实验室模拟部分井下场景的方式收集数据。

为弥补数据样本的不足,使模型能够学习到更丰富的特征,从而在面对各种复杂的现实场景时表现得更加稳健,使用 Albumentations 进行数据增强。Albumentations 提供了基本数据增强、模拟环境和像素级调整 3 类数据增强。基本数据增强操作包括翻转、旋转和缩放等转换;像素级调整可以对图像进行亮度、饱和度调整,并添加噪声等操作以模拟现实世界的变化。由于天气变化对井下环境影响较小,因此本次只使用基本数据增强和像素级调整 2 个功能。

1.3 数据标注

在深度学习领域,数据标注质量直接影响模型性能。精确标注数据能够为模型提供准确的监督信号,

使模型在训练过程中可以有效学习到数据中的关键特征和模式。然而,当面对大规模数据集时,手工标注耗时长,且需要极强的专业性并长期保持高度的专注,一旦出现错标、漏标等情况,模型最终效果将会受到巨大影响。为此,本文使用一种半自动训练方法,流程如图 1 所示。第一步,选出少量典型样本,尽可能涵盖各类特征。第二步,使用 LabelImg 进行手动标注,构建一个初步的数据集,并对模型进行预训练。第三步,取出部分数据使用该模型进行自动标注,保留置信度大于 0.7 的标注结果。第四步,使用 Label-Img 对自动标注的数据进行手动调整,得到一个新数据集,对模型进行重新训练。重复步骤三和步骤四,直至数据全部标注完成。

2 模型构建与训练

2.1 模型简介

本次选择 YOLOv11 作为识别模型,相较于 YOLOv8,




图 1 数据标注流程

Fig. 1 Data annotation process

YOLOv11 实现了精度、速度和效率的全面提升。其核心改进包括采用 C3K2 模块替代 YOLOv8 的 C2f 模块,通过多尺度卷积核动态扩展感受野并优化特征提取性能,同时在 SPPF 模块后新增 C2PSA 模块,结合金字塔切片注意力机制(PSA)增强多尺度特征融合,有效提升复杂场景下的检测精度。

2.2 参数设置

YOLOv11 为模型参数设置提供了多个超参数配置,包括批处理大小、学习率、权重衰减等。设置 epochs=150,对整个训练数据集进行 150 次完整的迭代训练,设置早停法 patience=10,连续 10 个训练轮次内,验证集的性能指标(如损失值)没有得到改善,训练过程将提前停止,避免继续训练模型导致其过度拟

合训练数据的噪声和特征,降低模型的泛化能力。使用 AdamW 优化器,根据损失函数的梯度信息更新模型参数,以最小化损失函数;通过计算梯度的一阶矩估计和二阶矩估计来动态调整每个参数的学习率。

2.3 评价指标

在目标检测领域,平均精度均值(mAP)和混淆矩阵是评估模型性能的重要指标。平均精度(AP)是针对每个类别而言的,是精确率-召回率(PR)曲线下的面积。mAP 则是所有类别 AP 的平均值,是目标检测中广泛使用的综合评价指标,能够全面反映模型在多个类别的检测性能,其计算公式为:

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \tag{1}$$

式中: C 为类别的数量; AP_i 为第 i 个类别的平均精度。

混淆矩阵元素可分为对角元素和非对角元素。在多分类矩阵($n \times n$ 矩阵, n 为类别数)中,对角元素 $C_{ii}(i=1,2,\cdots,n)$ 为实际属于第 i 类且被模型正确预测为第 i 类的样本数量;非对角元素 $C_{ij}(i \neq j, i=1,2,\cdots,n; j=1,2,\cdots,n)$ 为实际属于 j 类但被模型错误预测为第 i 类的样本数量。通过对混淆矩阵及其指标的分析,可以全面、深入地了解模型在不同方面的性能,从而更好地判断模型的训练效果,并针对模型的不足进行改进。

3 试验与结果

3.1 训练分析

本次试验使用 Pytorch 2.4.1 框架结合 CUDA 12.1 计算架构进行训练, GPU 采用 RTX 4070s。按 7:3 的比例划分训练集和测试集,并统一调整图像像素为

640×640,以便于后续批量处理和特征提取。

训练结果如图 2 所示。从图 2-a)、b)可以看出:经 Albumentations 进行数据增强后,模型性能得到大幅提升,模型平均精度均值由原来的 0.792 提升至 0.845。从图 2-c)可以看出:模型对“somke”类别正确分类比例仅为 0.40,大量“smoke”被误判为其他类别,表明模型对“smoke”特征的学习和区分能力不足;“background”类别被误判的情况较多,误判为“fire”的比例达 0.28,误判为“masks”的比例为 0.60,说明模型难以将背景和这些前景类别准确区分开,对背景特征的识别存在较大偏差。经数据增强后(如图 2-d)所示),模型对类别的正确分类能力增强,多数类别的对角元素更高,非对角元素也大幅降低,增强后的模型对各类别分类的准确性整体优于增强前,错误分类的情况有所改善。




图2 模型训练结果对比

Fig. 2 Comparison of model training results

3.2 识别结果

为验证模型效果,选出部分图片进行识别测试,结果如图 3-a)、b)所示。该模型可有效监测安全帽和口罩佩戴情况。危险区域监测结果如图 3-c)所示。当人员闯入危险区域时,区域监测框标红并显示“Trespassing into dangerous areas”标签。皮带上异物

的检测结果如图 3-d)所示,该模型可有效识别皮带上异物,避免人员受伤。综上,该模型监测效果较好,可有效识别未戴安全帽、闯入危险区域等行为,并通过监测框标红的方式向管理人员发出警报,后期也可通过增加警示灯、报警器等设备,提高报警信息的视听程度,以便于工作人员及时察觉异常情况并做出响

应。同时,YOLOv11轻量级的设计思路,可对监控视频进行实时监测。当出现异常情况时,可第一时间警报,降低了人工监测成本,同时也减少了事件处理的响应时间,有效克服了视频监控方式的弊端,对井下人员安全监管具有重大意义。




图3 部分样本识别效果展示

Fig. 3 Recognition results of selected samples

4 结 论

1)基于YOLOv11构建的井下人员不安全行为识别模型识别效果较好,可以有效监测防护设备穿戴情况、危险区域闯入等情况,克服了传统监测手段的弊端,对井下安全管理具有重要作用。但是,井下环境复杂,存在光照强度低、图像噪声大等问题,这些因素会极大影响模型识别精度,后续需要考虑如何提升模型暗部识别能力及图像去噪问题。

2)通过使用原始数据集和增强后数据集对模型进行训练,训练结果对比表明:使用Albumentations对原始数据增强来提升模型精确度的方式是可行的,通过对原始数据进行添加噪声、模糊等操作模拟真实井下环境,从而构建的新数据集可以很好增强模型的鲁棒性和泛化性,使模型可以更好地学习图像特征。

3)相较于人工标注的方式,使用半自动标注的方式对数据进行标注可大幅提高标注效率,降低所需人力资源,且标注精度也有明显改善,可有效提高训练数据质量。

[参 考 文 献]

[1] 赵兴东. 黄金矿山深井开采研究进展与发展趋势[J]. 黄金, 2024, 45(8): 1-18.

- [2] FU G, XIE X C, JIA Q S, et al. Accidents analysis and prevention of coal and gas outburst: Understanding human errors in accidents[J]. Process Safety and Environmental Protection, 2020, 134: 1-23.
- [3] 孙宁昊, 郭钰, 董国宇, 等. 煤矿井下作业人员不安全行为概念辨析研究[J]. 煤矿安全, 2025, 56(5): 245-250.
- [4] PAUL P S, MAITI J. The role of behavioral factors on safety management in underground mines[J]. Safety Science, 2006, 45(4): 449-471.
- [5] SONG Y T, ZHANG S. The differences in risk perception between practitioners in the non-coal-mining industry: Miners, managers and experts[J]. Toxics, 2022, 10(10): 623.
- [6] 李国为, 田水承. 煤矿岗前人员不安全状态智能检测系统研究——以红柳林煤矿为例[J]. 中国安全生产科学技术, 2023, 19(2): 106-113.
- [7] WU M L, YE Y C, KE L H, et al. Characteristics analysis and situation prediction of production safety accidents in non-coal mining[J]. Resources Policy, 2023, 83: 103745.
- [8] SALAS M L, QUEZADA S, BASAGOITIA A, et al. Working conditions, workplace violence and psychological distress in Andean miners: A cross-sectional study across three countries[J]. Annals of Global Health, 2015, 81(4): 465-474.
- [9] 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.
- [10] 吴博, 李永胜, 王睿, 等. 基于自训练的多标签岩矿石薄片分类方法[J]. 黄金, 2024, 45(2): 61-67.
- [11] 胥维, 迟洪鹏, 战凯. 基于3D视觉的炮孔智能识别方法研究[J]. 黄金, 2025, 46(1): 6-10.
- [12] 李涛, 孙琰, 侯建硕, 等. 人工智能在矿山设备预测性维护中的应用研究[J]. 黄金, 2025, 46(1): 1-5, 19.
- [13] 刘浩, 刘海滨, 孙宇, 等. 煤矿井下员工不安全行为智能识别系统[J]. 煤炭学报, 2021, 46(增刊2): 1 159-1 169.
- [14] 张帆, 张嘉荣. 基于深度学习的矿井智能目标检测技术研究综述[J]. 煤炭科学技术, 1-14[2025-03-10]. <http://kns.cnki.net/kcms/detail/11.2402.TD.20240903.1434.002.html>.
- [15] 陈伟, 江志成, 田子建, 等. 基于YOLOv8的煤矿井下人员不安全动作检测算法[J]. 煤炭科学技术, 2024, 52(增刊2): 267-283.
- [16] IMAM M, BAĬNA K, TABII Y, et al. Ensuring miners' safety in underground mines through edge computing: Real-time pose estimation and PPE compliance analysis[J]. IEEE Access, 2024, 12: 145 721-145 739.
- [17] 王安佳, 陈世涛. 基于视频分析技术的选煤厂人员不安全行为识别研究与应用[J]. 洁净煤技术, 2023, 29(增刊1): 164-168.
- [18] 李立功, 刘晓, 赵旭. 基于深度学习的地下工程施工人员不安全行为识别研究[J]. 中国安全生产科学技术, 2025, 21(5): 55-62.
- [19] 李华, 吴立舟, 钟兴润, 等. 基于计算机视觉的人员疲劳状态与不安全行为识别[J]. 中国安全科学学报, 2025, 35(3): 28-35.
- [20] 柯巍, 朱权洁, 陈长茂, 等. 基于改进YOLOV11的卷烟仓储人员不安全行为分类及识别[J]. 中国安全科学学报, 2025, 35(3): 36-44.

(下转第41页)

[27] 张金浩.GNSS 自动化监测应用场景及前景[J].现代传输,2025 (2):61-64.

Design and application of the online monitoring system for the Tonglushan tailings pond

Xiong Guoxiong¹, Wang Huan¹, Bi Cheng^{2,3}, Wang Yong^{2,3}

(1. Tonglushan Copper-Iron Mine, Daye Nonferrous Metals Co., Ltd.;

2. School of Civil and Resource Engineering, University of Science and Technology Beijing;

3. Key Laboratory of Ministry of Education for Efficient Mining and Safety of Metal Mine)

Abstract: The tailings pond at the Tonglushan Copper-Iron Mine has already been decommissioned. To ensure its long-term safety and stability after closure, an online monitoring system based on GNSS technology was developed, tailored to the current conditions of the facility. This paper presents the overall architecture of the monitoring system, including the design of GNSS monitoring stations, layout of monitoring points, equipment selection and installation, and the development of an online monitoring information management system based on SOA. The system enables deformation analysis of the tailings pond and investigates the causes of deformation. Key risk points requiring focused monitoring are identified. Application of the system has significantly improved the management level of the Tonglushan tailings pond, reduced the long-term post-closure monitoring and maintenance workload, and provided a valuable reference for similar mines.

Keywords: tailings pond; online monitoring system; GNSS; Tonglushan Copper-Iron Mine; information management; intelligentization

(上接第 35 页)

Research on underground personnel unsafe behavior recognition based on YOLOv11

Jiang Dongsheng^{1,2}, Zhu Quanjie^{1,2}, Hao Yingnan^{1,2}, Chen Yuxiang^{1,2}

(1. School of Emergency Technology and Management, North China Institute of Science and Technology;

2. School of Culture and Communication, Institute of Disaster Prevention)

Abstract: The underground working environment is complex and full of safety hazards, while traditional supervision methods are limited and incapable of providing comprehensive real-time monitoring. Therefore, research on recognizing unsafe behaviors of underground personnel using machine learning has become increasingly urgent. This study proposes a recognition method and model for underground personnel's unsafe behaviors based on YOLOv11. Unsafe behaviors are categorized into 3 types: protective equipment-related, hazardous area-related, and dangerous behavior-related. A dataset was constructed according to these categories. The Albumentations was used for data augmentation, simulating underground environmental variations by adjusting lighting conditions, adding noise, and more, to enhance model generalization and robustness. Finally, a semi-automatic labeling method was adopted for data annotation, and the model was trained. The results show that the model, after data augmentation with Albumentations and using semi-automatic labeling, achieved good performance without requiring extensive manual annotation.

Keywords: YOLOv11; unsafe behavior; behavior recognition; data augmentation; Albumentations; semi-automatic annotation