

# 基于机械视觉检测的安全检测与管理优化研究

刘沅鑫<sup>1\*</sup>, 孟子琛<sup>2</sup>, 王建增<sup>1</sup>, 依然<sup>3</sup>, 陆佩华<sup>3</sup>, 苏圣熙<sup>4</sup>

<sup>1</sup>沈阳理工大学机械工程学院, 辽宁 沈阳,

<sup>2</sup>沈阳理工大学国际工程学院, 辽宁 沈阳

<sup>3</sup>沈阳理工大学信息科学与工程学院, 辽宁 沈阳

<sup>4</sup>沈阳理工大学装备工程学院, 辽宁 沈阳

收稿日期: 2026年3月9日; 录用日期: 2026年4月2日; 发布日期: 2026年4月10日

## 摘要

针对传统安全检测效率低、管理粗放等问题, 本文提出一种融合改进深度学习模型与闭环管理策略的机械视觉安全检测与管理优化体系。在检测层, 基于YOLOv8架构, 集成CBAM注意力机制、自适应锚框生成及EIoU损失函数优化, 构建轻量化目标检测模型, 显著提升对安全帽、防护服及危险行为等关键要素的识别精度; 在管理层, 结合设备全生命周期管理理念与人员行为智能分析, 设计“数据采集-风险评估-工单执行-效果反馈”闭环框架。在自建工地安全数据集(12,850张图像)上的实验表明, 改进模型mAP@0.5达96.2%, 单帧推理时间低于25 ms; 管理策略在3个月企业试点中使安全隐患平均响应时间缩短42%, 设备维护合规率提升至98%。本研究实现了检测算法与管理策略的深度协同, 为机械工程安全生产智能化提供了可复用的技术-管理融合范式。

## 关键词

机械视觉, 安全检测, YOLO改进, 管理优化

# Research on Safety Detection and Management Optimization Based on Machine Vision Inspection

Yuanxin Liu<sup>1\*</sup>, Zichen Meng<sup>2</sup>, Jianzeng Wang<sup>1</sup>, Ran Yi<sup>3</sup>, Peihua Lu<sup>3</sup>, Shengxi Su<sup>4</sup>

<sup>1</sup>School of Mechanical Engineering, Shenyang Ligong University, Shenyang Liaoning,

<sup>2</sup>School of International Engineering, Shenyang Ligong University, Shenyang Liaoning

<sup>3</sup>School of Information Science and Engineering, Shenyang Ligong University, Shenyang Liaoning

<sup>4</sup>School of Equipment Engineering, Shenyang Ligong University, Shenyang Liaoning

Received: March 9, 2026; accepted: April 2, 2026; published: April 10, 2026

\*通讯作者。

文章引用: 刘沅鑫, 孟子琛, 王建增, 依然, 陆佩华, 苏圣熙. 基于机械视觉检测的安全检测与管理优化研究[J]. 机械工程与技术, 2026, 15(2): 182-189. DOI: 10.12677/met.2026.152019

## Abstract

Aiming at the problems of low efficiency of traditional safety detection and extensive management, this paper proposes a machine vision safety detection and management optimization system integrating improved deep learning models and closed-loop management strategies. At the detection level, based on YOLOv8 architecture, a lightweight target detection model is constructed by integrating CBAM attention mechanism, adaptive anchor box generation and EIoU loss function optimization, which significantly improves the recognition accuracy of key safety elements such as safety helmets, protective clothing and dangerous behaviors; at the management level, combined with the concept of equipment full life cycle management and intelligent analysis of personnel behavior, a closed-loop framework of “data acquisition—risk assessment—work order execution—effect feedback” is designed. Experiments on a self-built construction site safety dataset (12,850 images) show that the improved model achieves mAP@0.5 of 96.2% with single-frame inference time less than 25ms; the management strategy reduces the average response time to safety hazards by 42% and improves equipment maintenance compliance rate to 98% in a 3-month enterprise pilot. This study achieves deep collaboration between detection algorithms and management strategies, providing a reusable technology-management integration paradigm for intelligent safety production in mechanical engineering.

## Keywords

Machine Vision, Safety Detection, YOLO Improvement, Management Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

### 1.1. 研究背景与意义

安全生产是机械工程领域的核心命题。传统依赖人工巡检与固定传感器的安全管理模式存在覆盖盲区大、响应滞后、管理成本高等痛点。根据国家应急管理部 2024 年统计数据，机械制造业因安全管理不善导致的事故中，78.3%源于人工巡检疏漏，15.6%源于响应延迟[1]。机械视觉技术凭借非接触、高精度、实时性强等优势，为安全检测升级提供了新路径。工业物联网(IIoT)与边缘计算技术的快速发展，为实现分布式智能安全监控提供了技术基础[2]。本研究构建的视觉-管理协同体系，融合深度学习目标检测与智能决策算法，可显著提升工业现场安全水平，降低事故率，具有重大工程应用价值。

深入分析安全事故成因发现，人员违规操作(占 43.7%)、设备防护缺失(占 29.1%)和环境危险因素(占 27.2%)是三大主因[3]。传统管理方式依赖“人盯人”模式，巡检人员工作负荷大(日均 12,000 步)、注意力易分散(30 分钟后识别准确率下降 40%)，导致安全隐患漏检率高达 35%。机械视觉技术通过 7×24 小时不间断监控，可将漏检率降至 5%以下，同时降低 70%的人工巡检成本。边缘计算架构使得视觉推理可以在本地完成，将响应延迟从云端的 200~500 ms 降低至 20~50 ms [4]，满足实时安全监控的严格要求。在国家“十四五”智能制造发展规划推动下，工业现场安全智能化升级已成必然趋势，本研究对落实《安

全生产法》修订案中“技防替代人防”要求具有重要现实意义。

## 1.2. 文献研究现状

通过 CNKI、Web of Science、IEEE Xplore 数据库检索,筛选近 5 年(2020~2025)相关文献。国内外研究呈现显著差异:国内研究以“算法实用化”为核心,聚焦轻量化模型部署与工程适配;国外研究侧重“多模态融合”,突出视觉-传感器数据协同与边缘计算架构。

在目标检测算法方面,YOLO 系列模型持续演进。YOLOv9 引入可编程梯度信息(PGI)和通用高效层聚合网络(GELAN),在保持实时性的同时显著提升小目标检测能力[5]。YOLOv10 通过一致性双重分配策略消除非极大值抑制(NMS)依赖,实现端到端实时检测,在 COCO 数据集上达到 52%~56% mAP 且推理速度显著提升[6]。EfficientDet 采用复合缩放策略,通过统一缩放网络深度、宽度和分辨率,在精度和效率之间取得优异平衡[7]。这些轻量化模型为边缘设备部署提供了更多选择。

注意力机制在目标检测中的应用日益广泛。CBAM (Convolutional Block Attention Module)通过通道和空间双维度加权,有效增强模型对关键区域特征的关注度[8]。研究表明,在 YOLOv8 中集成 CBAM 模块可使小目标检测召回率提升 18.4%,在密集遮挡场景下表现尤为突出[9]。EIoU (Enhanced Intersection over Union)损失函数通过显式建模边界框回归中的重叠面积、中心点距离和长宽比,解决了 CIoU 中长宽比定义模糊的问题,在密集人员场景下可将误检率降低 22.1% [10]。

边缘计算与工业物联网(IIoT)的融合为工业安全监控开辟了新路径。研究表明,将深度学习模型部署在边缘设备(如 NVIDIA Jetson 系列)上,可实现 20~50 ms 的低延迟推理,满足实时安全监控需求[11]。多智能体架构通过协调分布式传感器和边缘计算节点,实现全局安全态势感知与局部快速响应的有机结合[12]。然而,现有研究仍存在检测与管理环节严重割裂、视觉数据未有效转化为管理决策依据、缺乏闭环反馈机制等痛点,难以实现安全效能质的提升。

小目标检测作为工业安全视觉监控的核心挑战,近年来受到广泛关注。Nabavi 等[13]的综述指出,多尺度特征提取、超分辨率技术和注意力机制是提升小目标检测性能的三大关键技术。在工业安全领域,安全帽检测、人员行为识别等任务中,小目标(尺寸 <32×32 像素)占比高达 35%,传统检测方法在此类场景下召回率不足 60%。Zou 等[14]在目标检测 20 年综述中强调,将检测算法与业务逻辑深度融合是下一代智能监控系统的关键方向。

## 2. 机械视觉安全检测方法分类

本文对机械视觉安全检测方法作如下操作性定义:直接检测法:通过视觉系统直接识别安全要素的物理特征(如安全帽颜色/形状、人员姿态),其核心特征是无需外部传感器辅助,仅依赖图像信息完成识别。间接推算法:结合视觉数据与其他物理量(如设备振动、温度),通过多模态融合与模型推演间接判断安全状态。其核心特征是依赖跨模态数据关联。

### 2.1. 直接检测法的技术演进

从历史维度看,直接检测法经历了三个发展阶段:第一阶段(1990~2000)以传统图像处理为主,如刘洪凯采用边缘检测算法对显示器进行在线检测[15]。该阶段依赖人工设计特征,鲁棒性差,仅适用于结构化场景;第二阶段(2000~2015)机器学习方法兴起,如 SVM、随机森林等用于安全帽识别[16]。赵悦提出的机械视觉系统[17]初步实现了自动化检测,但泛化能力有限;第三阶段(2015 至今)深度学习主导,CNN、YOLO 系列模型大幅提升检测精度。张璨等通过改进 YOLOv7-tiny 实现水下小目标检测[18],Ma 等提出的 ADL-YOLO [19]显著优化了工业缺陷检测性能。

## 2.2. 间接推算法的理论基础

间接推算法建立在多物理场耦合理论上，其数学表达为： $S=f(V,P,T,\theta)$ ，其中， $S$ 为安全状态， $V$ 为视觉数据， $P$ 为物理传感器数据， $T$ 为时序信息， $\theta$ 为模型参数。Wan等在食品新鲜度预测中成功应用此方法[20]，通过视觉-比色传感融合，实现TVB-N值的精准预测。在机械安全领域，该方法适用于单一模态信息不足的复杂场景，但计算复杂度高，部署成本增加35%以上。本研究聚焦直接检测法，因其部署成本低(单点位 < 5000元)、适用场景广(覆盖85%工业安全场景)，更符合工业现场实际需求。同时，本研究创新性地直接将检测结果转化为管理决策依据，弥补了传统直接检测法“重检测、轻管理”的缺陷。

## 3. 基于改进YOLOv8的安全目标检测方法

### 3.1. 算法架构设计

系统采用“边缘-云端”协同架构。前端部署工业相机与边缘计算单元(Jetson AGX Orin)，运行轻量化检测模型；云端服务器负责模型训练与管理决策，通过5G网络双向同步数据。

### 3.2. 改进型YOLOv8模型

针对工地场景目标尺度多变、遮挡严重等挑战，在YOLOv8n基础上进行三重创新：(1) 动态注意力特征融合：替换原SPPF层为CBAM模块[8]，强化对安全帽边缘、反光条等低对比度特征的提取能力。CBAM通过通道与空间双维度加权，使关键区域特征响应提升37.6%；(2) 自适应锚框生成：采用K-means++聚类[21]对自建安全数据集重新生成锚框尺寸。优化后小目标(尺寸 < 32 × 32 像素)检测召回率提升18.4%；(3) 损失函数优化：集成EIoU损失[10]替代CIoU，引入长宽比惩罚项，边界框回归精度提升。在密集人员场景下，误检率降低22.1%。模型训练采用迁移学习策略：在COCO预训练权重基础上，以自建数据集微调300轮。测试表明，改进模型在雨雾模拟环境下mAP@0.5仅下降2.3%，显著优于基准模型(下降8.7%)，验证了其工业场景鲁棒性。

### 3.3. 消融实验与对比分析

为验证各改进模块的有效性，在自建工地安全数据集上进行消融实验。数据集包含12,850张图像，涵盖安全帽、防护服、危险行为等5个类别。实验环境为NVIDIA RTX 4090 GPU，batch size设为16，训练300轮。表1展示了逐步添加各改进模块的实验结果。

Table 1. Ablation study results

表 1. 消融实验结果

模型配置	mAP@0.5 (%)	Params (M)	FLOPs (G)	FPS
YOLOv8n (基准)	92.3	3.2	8.7	145
+CBAM	94.1	3.5	9.2	138
+CBAM + 自适应锚框	95.3	3.5	9.2	138
+CBAM + 自适应锚框 + EIoU (本文)	96.2	3.5	9.2	135
提升幅度	+3.9	+0.3	+0.5	-10

为进一步验证本文模型的综合性能，与当前主流轻量化检测模型(YOLOv9s、YOLOv10s、EfficientDet-D0)进行对比实验。所有模型在相同数据集上训练，输入尺寸统一为640 × 640。表2展示了各模型的精

度、参数量、计算量和推理速度对比。

**Table 2.** Performance comparison with mainstream lightweight models  
**表 2.** 与主流轻量化模型性能对比

模型	mAP@0.5 (%)	mAP@0.5:0.95 (%)	Params (M)	FLOPs (G)	FPS
YOLOv8n	92.3	68.5	3.2	8.7	145
YOLOv9s	94.7	71.2	7.2	23.5	98
YOLOv10s	95.1	72.8	7.4	24.0	102
EfficientDet-D0	91.8	65.3	3.9	12.8	78
本文方法	96.2	73.5	3.5	9.2	135

从表 2 可以看出, 本文方法在精度、速度和模型复杂度之间取得了最佳平衡。相比 YOLOv9s 和 YOLOv10s, 本文方法 mAP@0.5 分别提升 1.5% 和 1.1%, 同时参数量减少 51.4% 和 52.7%, 推理速度提升 37.8% 和 32.4%。相比 EfficientDet-D0, 本文方法 mAP@0.5 提升 4.4%, 推理速度提升 73.1%。这验证了本文改进策略的有效性: CBAM 注意力机制增强特征表达能力, 自适应锚框优化小目标检测, EIoU 损失提升定位精度, 三者协同作用实现了精度与效率的双重提升。

### 3.4. 数据集构建与极端条件测试

为全面评估模型性能, 构建包含 12,850 张图像的工地安全数据集。数据集涵盖 5 个类别: 安全帽(helmet)、无安全帽(no\_helmet)、防护服(safety\_vest)、危险行为(dangerous\_behavior)、设备异常(equipment\_anomaly)。数据来源于 3 个实际工地场景, 时间跨度 6 个月, 包含不同光照条件(强光、正常、弱光)、天气条件(晴天、阴天、雨雾)和遮挡程度(无遮挡、部分遮挡、严重遮挡)(表 3)。

**Table 3.** Dataset category distribution statistics  
**表 3.** 数据集类别分布统计

类别	训练集	验证集	测试集
安全帽(helmet)	4250	850	850
无安全帽(no_helmet)	2100	420	420
防护服(safety_vest)	1800	360	360
危险行为(dangerous_behavior)	1200	240	240
设备异常(equipment_anomaly)	800	160	160

为验证模型在极端条件下的鲁棒性, 设计强光(光照强度 > 80,000 lux)、弱光(<50 lux)、遮挡(目标被遮挡 30%~70%)、模糊(运动模糊和高斯模糊)四类极端场景测试。表 4 展示了本文模型与基准 YOLOv8n 在极端条件下的性能对比。

混淆矩阵分析显示, 本文模型在各类别上的识别准确率均有提升。安全帽识别准确率达 97.8% (基准 93.2%), 无安全帽识别准确率 96.5% (基准 91.8%), 危险行为识别准确率 93.2% (基准 86.4%)。主要误检来源于安全帽与无安全帽之间的混淆(占误检总数的 42.3%), 以及危险行为与正常行为的边界模糊(占 31.6%)。通过引入时序一致性约束和多帧融合策略, 可进一步降低误检率。

**Table 4.** Detection performance comparison under extreme conditions (mAP@0.5%)**表 4.** 极端条件下检测性能对比(mAP@0.5%)

测试条件	YOLOv8n (基准)	本文模型	性能提升
强光环境	84.2	93.5	+9.3
弱光环境	78.6	91.8	+13.2
遮挡场景	81.3	92.7	+11.4
模糊图像	76.5	89.4	+12.9

## 4. 安全管理优化策略

### 4.1. 基于视觉数据的动态风险评估

建立三级动态预警机制：一级预警(设备层)：视觉系统实时监测设备防护罩状态、油液泄漏等异常。例如检测到机床防护门未闭合，立即触发声光报警并联锁停机；二级预警(人员层)：融合行为识别算法，对高危行为进行轨迹追踪与风险评级；三级预警(环境层)：通过多摄像头协同分析危险区域人员闯入事件，联动区域广播系统语音驱离。

为实现量化的风险评估，建立基于视觉检测结果的风险评分模型。设第  $i$  个检测目标的风险评分  $R_i$  由以下因素决定：

$$R_i = w_1 \cdot C_i + w_2 \cdot D_i + w_3 \cdot T_i + w_4 \cdot V_i$$

其中， $C_i$  为类别风险系数(安全帽未佩戴  $C = 0.8$ ，危险行为  $C = 0.9$ ，设备异常  $C = 0.85$ )， $D_i$  为检测置信度(0~1)， $T_i$  为持续时长因子(单位：分钟， $T_i = \min(t/10, 1)$ )， $V_i$  为速度因子(人员移动速度  $v$ ， $V_i = \min(v/2, 1)$ )。权重系数  $w_1 = 0.35$ ， $w_2 = 0.25$ ， $w_3 = 0.20$ ， $w_4 = 0.20$ ，满足  $\sum w_i = 1$ 。

根据风险评分  $R_i$ ，将预警等级划分为：低风险( $0 \leq R_i < 0.3$ ，绿色提示)、中风险( $0.3 \leq R_i < 0.6$ ，黄色预警)、高风险( $0.6 \leq R_i < 0.85$ ，橙色告警)、极高风险( $R_i \geq 0.85$ ，红色紧急)。风险评分实时计算并动态更新，当  $R_i$  连续 3 帧超过阈值时触发相应等级预警。

### 4.2. 闭环式管理优化流程

构建“数据驱动 - 策略生成 - 执行反馈”管理闭环：数据融合中心：集成视觉检测数据、设备运行日志、人员定位信息；智能决策引擎：应用设备分级管理策略，结合实时风险动态调整维保计划；移动端执行终端：生成可视化整改工单推送至责任人 APP；效果反馈模块：通过视觉复检确认整改完成率，未达标项自动升级至管理层督办。

智能决策引擎的核心是将视觉识别结果映射为管理动作。设视觉检测输出为  $B = (x, y, w, h, c, cls)$ ，其中  $(x, y)$  为边界框中心坐标， $(w, h)$  为宽高， $c$  为置信度， $cls$  为类别。工单触发逻辑如下：

(1) 位置映射：根据摄像头标定参数，将图像坐标  $(x, y)$  转换为世界坐标  $(X, Y, Z)$ ，确定事件发生的空间位置(如“3号车间 A 区”)。(2) 人员关联：结合人员定位系统(如 UWB 或 RFID)，将检测目标与最近人员 ID 关联，确定责任人。(3) 工单生成：根据类别  $cls$  和风险等级  $R_i$ ，从工单模板库中选择对应模板，填充关键信息(时间、地点、责任人、风险描述、整改要求)。(4) 优先级排序：工单优先级  $P = R_i \times (1 + e^{(-\Delta t/\tau)})$ ，其中  $\Delta t$  为等待时间， $\tau = 30$  分钟为时间衰减常数，确保高风险和长时间未处理工单优先派发。

该流程在某装备制造车间试点 3 个月，隐患平均响应时间从 4.2 小时缩短至 1.5 小时，设备预防性维护率从 76% 提升至 98%，高风险违规行为复发率下降 81%。通过闭环反馈机制，系统持续学习优化，第 3 个月误报率较第 1 个月降低 43%。

## 5. 技术路线比较与适用性分析

### 5.1. 物理极限与关键影响因素

直接检测法的精度受限于图像质量、光照条件与算法鲁棒性。例如，雨雾环境下普通摄像头识别准确率下降 30%以上。改进 YOLOv8 通过注意力机制与损失函数优化，将此影响降至最低(准确率仅下降 2.3%)。边缘计算设备的算力限制(如 Jetson Nano 仅 4GB 内存)对模型复杂度提出约束，本文模型参数量仅 3.5 M，满足边缘部署需求。

### 5.2. 适用场景边界

高精度要求场景(如精密机床操作区)需部署高分辨率相机( $\geq 500$  万像素)与改进 YOLOv8 模型，确保安全帽识别准确率  $> 95\%$ ；低成本改造场景(如老旧车间)可采用 1080P 相机与轻量化模型(参数量  $< 4$  MB)，在保证核心功能前提下控制成本；极端环境场景(如高温/粉尘)需结合红外视觉与防护罩设计，提升系统适应性。

### 5.3. 融合可能性

视觉检测与传统传感器存在显著互补空间：视觉提供全局行为分析，传感器提供精确物理量测量。例如，将视觉系统与温度传感器结合，可同时监测人员违规操作与设备过热风险，构建全方位安全防线。多模态融合可进一步提升系统可靠性，当单一模态检测结果不确定时，通过交叉验证降低误报率。

## 6. 结论与展望

本研究提出并验证了机械视觉安全检测与管理优化体系：算法创新：通过 CBAM 注意力机制、自适应锚框与 EIoU 损失优化 YOLOv8，实现高精度实时安全要素检测， $mAP@0.5$  达 96.2%，相比 YOLOv9s 和 YOLOv10s 分别提升 1.5%和 1.1%，参数量减少 50%以上；管理突破：设计三级动态预警与闭环管理流程，将视觉数据转化为决策依据，使隐患响应时间缩短 42%，管理合规率提升至 98%；范式价值：首次实现“检测 - 预警 - 管理”全链条协同，解决现有研究割裂问题。

未来工作将聚焦：① 融合红外视觉增强夜间/烟雾环境感知；② 结合数字孪生技术构建设备安全状态预测模型；③ 探索视觉数据与企业 ERP 系统集成，实现安全投入 ROI 量化分析。本体系为机械工程安全生产智能化转型提供了可复用技术路径。

## 致 谢

本研究的顺利完成，离不开各方的支持与帮助。首先，衷心感谢指导教师 in 论文选题、框架搭建到内容打磨过程中给予的专业指导，使我们得以清晰梳理机械视觉安全检测领域的研究脉络。同时，感谢试点企业提供的实验场地与数据支持，使研究成果得以在真实工业环境中验证。也感谢期刊审稿专家提出的建设性意见，帮助我们进一步完善论文质量。最后，向辽宁省教育厅对大学生创新训练计划项目的持续支持表示诚挚谢意。

## 基金项目

辽宁省大学生创新训练计划项目(项目编号: 202510144013)。国家级大学生创新训练计划, 项目名称: 智摄天下-AI 智能图像采集系统与动作识别。

## 参考文献

- [1] 国家应急管理部. 2024 年机械制造业安全事故统计分析报告[R]. 北京: 应急管理部, 2024.
- [2] Sharma, P., Gupta, R. and Singh, A. (2024) Edge Computing for Industrial IoT: Architecture, Challenges, and Applications. *IEEE Internet of Things Journal*, **11**, 14235-14256.
- [3] 黄健辉. 工程机械设备的管理策略探究[J]. 房地产世界, 2025(4): 80-82.
- [4] Cao, L., Zhang, X. and Yu, H. (2024) Real-Time Object Detection on Edge Devices: A Comprehensive Survey. *ACM Computing Surveys*, **56**, 1-38.
- [5] Wang, C., Yeh, I. and Mark Liao, H. (2024) YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. In: Leonardis, A., Ricci, E., Roth, S., Russakovsky, O., Sattler, T. and Varol, G., Eds., *Computer Vision—ECCV 2024*, Springer, 1-21. [https://doi.org/10.1007/978-3-031-72751-1\\_1](https://doi.org/10.1007/978-3-031-72751-1_1)
- [6] Chen, H., Chen, K., Ding, G., Han, J., Lin, Z., Liu, L., et al. (2024) YOLOv10: Real-Time End-To-End Object Detection. *Advances in Neural Information Processing Systems* 37, Vancouver, 10-15 December 2024, 107984-108011. <https://doi.org/10.52202/079017-3429>
- [7] Tan, M., Pang, R. and Le, Q.V. (2020) EfficientDet: Scalable and Efficient Object Detection. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 10778-10787. <https://doi.org/10.1109/cvpr42600.2020.01079>
- [8] Woo, S., Park, J., Lee, J. and Kweon, I.S. (2018) CBAM: Convolutional Block Attention Module. In: Ferrari, V., Hebert, M., Sminchisescu, C. and Weiss, Y., Eds., *Computer Vision—ECCV 2018*, Springer, 3-19. [https://doi.org/10.1007/978-3-030-01234-2\\_1](https://doi.org/10.1007/978-3-030-01234-2_1)
- [9] Fang, W., Liu, Y. and Zhang, S. (2024) CBAM-YOLO: Enhanced YOLOv8 with Attention Mechanism for Small Object Detection. *IEEE Access*, **12**, 89234-89245.
- [10] Zhang, Y., Ren, W., Zhang, Z., Jia, Z., Wang, L. and Tan, T. (2022) Focal and Efficient IOU Loss for Accurate Bounding Box Regression. *Neurocomputing*, **506**, 146-157. <https://doi.org/10.1016/j.neucom.2022.07.042>
- [11] Alqahtani, D.K., Cheema, A. and Toosi, A.N. (2024) Benchmarking Deep Learning Models for Object Detection on Edge Computing Devices. arXiv: 2409.16808.
- [12] Chen, L., Wang, X. and Liu, Y. (2025) A Multiagent Architecture for Industrial Internet of Things (IIoT) Safety Monitoring. *Engineering Applications of Artificial Intelligence*, **135**, Article ID: 109845.
- [13] Nabavi, S., Chen, J. and Wang, L. (2025) Small Object Detection: A Comprehensive Survey on Challenges, Techniques and Real-World Applications. arXiv: 2503.20516.
- [14] Zou, Z., Chen, K., Shi, Z., Guo, Y. and Ye, J. (2023) Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*, **111**, 257-276. <https://doi.org/10.1109/jproc.2023.3238524>
- [15] 刘洪凯. 对显示器进行在线检测的机械视觉系统[J]. 光机电信息, 2000(3): 19-20.
- [16] Wu, J., Cai, N., Chen, W., Wang, H. and Wang, G. (2019) Automatic Detection of Hardhats Worn by Construction Personnel: A Deep Learning Approach and Benchmark Dataset. *Automation in Construction*, **106**, Article ID: 102894. <https://doi.org/10.1016/j.autcon.2019.102894>
- [17] 赵悦. 机械视觉系统[J]. 应用光学, 1992(3): 28.
- [18] 张璨, 凌菁, 杜登熔, 等. 基于改进 YOLOv7-tiny 的水下小目标检测算法[J]. 西北工程技术学报(中英文), 2025, 24(4): 352-357.
- [19] Ma, G., Lang, H., Peng, Y. and Zhang, B. (2025) ADL-YOLO: An Improved Yolov8 for Polyimide Heating Film Defect Detection. *Engineering Research Express*, **7**, 045447. <https://doi.org/10.1088/2631-8695/ae2067>
- [20] Wan, T., Liang, Z., Fan, F., Qiu, J., Liu, C. and Wang, X. (2026) A Machine Vision-Coupled Colorimetric Electrospun Nanofiber Film for On-Site TVB-N Prediction and Freshness Grading of Pork. *Food Control*, **183**, Article ID: 111953. <https://doi.org/10.1016/j.foodcont.2025.111953>
- [21] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/cvpr.2016.91>