

# 采煤工作面隐患目标检测中YOLO11与Faster R-CNN的对比研究

王耀杨<sup>1</sup>, 秦佳俊<sup>1</sup>, 王 翀<sup>2\*</sup>

<sup>1</sup>应急管理大学资源与环境学院, 河北 廊坊

<sup>2</sup>应急管理大学计算机与安全信息学院, 河北 廊坊

收稿日期: 2026年7月6日; 录用日期: 2026年8月10日; 发布日期: 2026年8月18日

## 摘 要

针对煤矿井下采煤工作面裂缝、鼓包、坍塌等隐患检测中样本有限、特征微弱的问题, 构建500张实景图像数据集, 对比YOLO11与Faster R-CNN。实验表明, YOLO11最优mAP50达94.80%, 精确率96.30%, 召回率89.60%, 参数量仅2.59 M, 推理速度72 FPS, 对细长裂缝等小目标检测完整精准; Faster R-CNN的mAP50为81.91%, 对大尺度坍塌较好, 但小目标漏检明显。YOLO11在精度与实时性上更具优势, 适合井下部署。

## 关键词

采煤工作面, 隐患检测, 目标检测, YOLO11, Faster-RCNN

# Comparative Study of YOLO11 and Faster R-CNN for Hidden Danger Detection in Coal Mining Face

Yaoyang Wang<sup>1</sup>, Jiajun Qin<sup>1</sup>, Chong Wang<sup>2\*</sup>

<sup>1</sup>School of Resources and Environment, University of Emergency Management, Langfang Hebei

<sup>2</sup>School of Computer and Information Security, University of Emergency Management, Langfang Hebei

Received: July 6, 2026; accepted: August 10, 2026; published: August 18, 2026

## Abstract

To address the issues of limited samples and weak features in detecting cracks, bulges, and collapses

\*通讯作者。

文章引用: 王耀杨, 秦佳俊, 王翀. 采煤工作面隐患目标检测中YOLO11与Faster R-CNN的对比研究[J]. 计算机科学与应用, 2026, 16(8): 138-148. DOI: 10.12677/csa.2026.168269

on underground coal mining faces, a dataset of 500 real-scene images is constructed to compare YOLO11 and Faster R-CNN. Results show that YOLO11 achieves a best mAP50 of 94.80%, precision 96.30%, recall 89.60%, with only 2.59 M parameters and 72 FPS, accurately detecting slender cracks and small hazards. Faster R-CNN obtains mAP50 of 81.91%, performing well on large collapses but missing small targets. YOLO11 is superior in accuracy and real-time performance, making it more suitable for underground deployment.

## Keywords

Coal Mining Face, Hidden Danger Detection, Object Detection, YOLO11, Faster-RCNN

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

矿井下采煤工作面是煤炭生产的核心区域，也是安全事故高发区域。受地质构造、采动影响、矿压等因素作用，工作面煤壁与顶板易出现裂缝、鼓包、局部坍塌三类典型隐患。若不能及时发现与处置，极易引发冒顶、片帮、漏顶等事故，严重威胁作业人员安全与设备稳定运行。

采煤工作面作为井下动态推进的狭长作业空间，煤壁与顶板状态持续变化，隐患的形态与位置随之动态演变。受高粉尘、低光照、水雾干扰以及采煤机、液压支架等大型设备的视觉遮挡影响，工作面图像获取质量差、有效信息占比低。传统人工巡检需在空间受限、风险较高的工作面内近距离观察，不仅效率低、周期长，而且漏检率高、主观性强，难以满足实时监测与快速预警的需求。

随着深度学习技术发展，基于目标检测的智能识别方法为采煤工作面隐患自动检测提供了可行路径。但井下隐患样本获取难度大、隐患形态复杂多变、小目标特征微弱，工程实践中普遍面临样本规模有限、弱特征、复杂背景的检测难题。现有目标检测算法在充足样本下性能优异，但在井下采煤工作面有限样本隐患检测场景中的适用性仍需系统验证。

因此，开展面向采煤工作面这三类典型隐患的有限样本检测算法对比研究，筛选精度高、速度快、适配性强的模型，对提升煤矿安全监测智能化水平、保障采煤工作面安全生产具有重要工程应用价值。

### 1.2. 相关工作

目标检测算法主要分为单阶段与两阶段两类。Faster R-CNN 作为两阶段算法代表，检测精度较高，但模型结构复杂、训练周期较长、对样本规模依赖性较强[1]；YOLO 系列算法作为单阶段代表，采用端到端回归检测，具有速度快、轻量化、易部署的优势，更适合工业现场实时检测[2]。

在煤矿领域，现有研究多集中于巷道[3][4]、皮带运输[5]、设备故障等场景，或围绕图像去噪[6]、数据集标注优化[7]、迁移学习[8]等辅助技术展开。针对采煤工作面裂缝、鼓包、坍塌三类核心隐患的有限样本检测研究仍较少，目前仅有少量数据集构建工作[9]，且缺乏对不同算法在井下复杂环境下的系统性对比。

为此，本文以采煤工作面实际采集的有限规模数据集为基础，围绕裂缝、鼓包、坍塌三类隐患，对比 YOLO11 与 Faster R-CNN 的检测性能、收敛速度与可视化效果，为采煤工作面智能隐患检测提供实用技术参考。

1.3. 模型结构概述

为便于理解两类算法在检测性能上的差异，本节分别介绍 YOLO11 与 Faster R-CNN 的核心结构，图 1 与图 2 为两者的网络结构示意图。




Figure 1. Network structure diagram of YOLO11  
图 1. YOLO11 网络结构图

本文实验所用 YOLO11n 为 Ultralytics 官方完整迭代开发的新一代轻量化单阶段检测模型，并非对 YOLOv8n 的复用、裁剪或二次改进。二者虽共享 C2f 基础模块设计思路，但 YOLO11 完成全网络梯度通路、多尺度融合、检测头范式三重升级，天然适配煤矿井下弱特征、细长裂缝小目标检测任务，核心适配逻辑如下：

(1) C2f 骨干模块优化梯度回流，保留细微弱特征

相较于前代 C3 结构，C2f 采用双分叉卷积分支，延长梯度反向传播路径，能够完整留存煤壁细长裂缝的浅层边缘纹理；井下粉尘、弱光会造成隐患特征对比度大幅衰减，该模块可避免浅层小目标特征在多层卷积中丢失，从特征提取源头缓解裂缝漏检问题；同时内置轻量化通道剪枝机制，在不损失弱特征信息前提下压缩模型参数量，适配井下算力有限的边缘监控设备。

(2) PAN-FPN 双向多尺度特征融合，兼容多尺寸隐患

采煤工作面同时存在毫米级细长裂缝、中型鼓包、大面积坍塌三类尺度差异极大的隐患，YOLO11 颈部 PAN-FPN 融合自上而下高层语义特征与自下而上浅层细节特征，实现大小目标特征均衡强化，解决单

一尺度网络难以兼顾裂缝小目标、坍塌大目标的痛点。

### (3) 无锚框解耦检测头，降低弱特征学习门槛

传统锚框机制需人工适配目标尺寸，井下裂缝形态无固定长宽比例，锚框超参数难以调优；YOLO11采用无锚框范式，直接回归目标中心、宽高与类别置信度，减少超参数对小样本训练的干扰；分类、边界框回归、置信度预测分支解耦，三类任务互不干扰，有限样本下对微弱隐患特征的学习效率显著提升。

因此 YOLO11 是 YOLO 系列的最新单阶段检测模型。本文选用轻量化版本 YOLO11n，其骨干网络采用 C2f 结构，相比前代进一步优化了梯度流，提升了特征提取效率。颈部(Neck)采用 PAN-FPN，通过自顶向下和自底向上的双向融合，增强多尺度特征的表达能力。检测头为解耦结构，分别预测类别、边界框回归和置信度，并采用无锚框机制，简化超参数设置。整体设计目标是在保持高精度的同时实现低延迟、轻量化，便于工业部署。

Faster R-CNN 是经典的两阶段检测算法。本文以 ResNet50 为主干网络，并附加 FPN 进行多尺度特征提取。第一阶段：区域提议网络(Region Proposal Network, RPN)在特征图上滑动锚框，生成候选区域(region proposals)，并筛选出约 2000 个前景提议框。第二阶段：RoI 池化将每个提议框映射到特征图上，通过全连接层进行类别分类和边界框精调。两阶段结构通过“先粗筛后细分”的策略，理论上可获得更高的定位精度，但对训练样本的数量和质量更为敏感。




Figure 2. Network structure diagram of Faster R-CNN

图 2. Faster R-CNN 网络结构图

两类算法的核心差异在于 YOLO11 将检测视为单次回归任务，速度快、参数量小；Faster R-CNN 将检测分解为“提议生成 + 分类精调”两步，精度潜力高但依赖更多样本。本文在有限样本的采煤工作面隐患数据集上对比两者，旨在验证单阶段模型在工业弱特征场景下的实际优势。

## 2. 实验设计

### 2.1. 数据集构建

本次实验图像全部取自冀东地区 3 座在产煤矿综采工作面，包括营沙壕煤矿 51,105 工作面、蒙泰未来梁 4202 工作面、101 综采工作面；采集设备选用井下防爆高清网络摄像头，支持 1080 P 高清成像。

采集环境覆盖井下典型复杂工况：光照分为强光局部补光、弱光巷道远端、无辅助照明三类；粉尘分为低粉尘常态、采煤割煤高粉尘、水雾降尘高干扰场景；同时包含液压支架遮挡、管线遮挡、煤壁大面积污渍遮挡等多种干扰工况，保证数据集环境多样性，贴合并下真实监测画面。

数据集总计采集、筛选有效实景图像 500 张，包含裂缝(crack)、鼓包(bulge)、坍塌(collapse)三类典型工作面隐患，采用 LabelImg 工具完成边界框标注，同步输出 VOC、YOLO 两种标准格式文件。

单类隐患图像数量统计：含裂缝图像 204 张、含鼓包图像 261 张、含坍塌图像 389 张；单张图像可同时包含多种隐患，三类隐患标注实例累计 854 个。各类隐患形态区分：裂缝为细长条状低对比度小目标，鼓包为局部凸起中型目标，坍塌为大面积垮落大尺度目标。

数据集按训练集：验证集：测试集 = 8:1:1 的比例随机分层划分，分层划分保证三类隐患在三个子集内分布均衡，避免单类隐患集中于某一子集。划分结果：训练集 400 张，用于模型权重迭代；验证集 50 张，用于训练过程超参数调优、最优模型筛选；独立测试集 50 张，全程隔离不参与训练、调参，用于客观评估模型泛化性能，保障实验结果严谨可靠。

## 2.2. 实验环境与配置

实验硬件配置为：CPU 为 Intel Core i7-12700K，GPU 为 NVIDIA RTX3090，内存 32 GB，存储 512 GB SSD。软件环境方面，操作系统为 Windows10 专业版，深度学习框架为 PyTorch1.12.1，Python 版本 3.8.13，辅助库包括 OpenCV4.5.5、NumPy1.21.6、Matplotlib3.5.3 等。

为保证实验公平性与可比性，YOLO11 与 Faster R-CNN 均使用官方预训练权重，采用完全相同的数据增强策略、统一优化器类型，在相同硬件环境下完成训练与速度测试。由于单阶段与两阶段模型的网络结构、损失函数与优化特性存在本质差异，需为各模型配置其官方推荐且适配自身结构的超参数，以确保模型均达到最佳收敛状态；同时受模型显存占用差异影响，采用硬件限制下可稳定运行的 Batch Size。YOLO11 选用 YOLO11n 轻量化模型，骨干为 C2f 结构，Neck 采用 PAN-FPN，输入尺寸  $640 \times 640$ ；Faster R-CNN 采用的主干网络为 ResNet50 + FPN，输入尺寸  $600 \times 600$ 。两种算法核心训练参数配置如表 1 所示。

**Table 1.** Model parameter configuration  
**表 1.** 模型参数配置

| 配置参数       | YOLO11            | Faster-RCNN                             |
|------------|-------------------|-----------------------------------------|
| 训练轮次       | 200 轮             | 200 轮                                   |
| 优化器        | Adam              | Adam                                    |
| 初始学习率      | 1e-03             | 5e-06                                   |
| 最小学习率      | 1e-05             | 5e-08                                   |
| 训练策略       | 自适应学习率衰减          | 冻结训练 + 解冻训练                             |
| Batch Size | 12                | 4                                       |
| 损失函数       | (box + cls + dfl) | (rpn_cls + rpn_loc + roi_cls + roi_loc) |

## 2.3. 评价指标

采用目标检测领域常用评价指标：平均精度均值(mAP50)、精确率(Precision)、召回率(Recall)、F1 分数；同时增加模型参数量、计算量 GFLOPs、推理速度 FPS 等实时性与部署指标，全面评估模型精度与实时性能。

### 3. 实验结果与分析

#### 3.1. 总体性能对比

两种模型整体检测性能指标如表 2 所示。

**Table 2.** Overall performance comparison of models  
**表 2.** 模型总体性能对比

| 评价指标      | YOLO11      | Faster-RCNN | 性能差异     |
|-----------|-------------|-------------|----------|
| 最优 mAP50  | 94.80%      | 81.91%      | +12.89%  |
| 精确率       | 96.30%      | 52.09%      | +44.21%  |
| 召回率       | 89.60%      | 90.26%      | -0.66%   |
| F1 分数     | 92.85%      | 65.72%      | +27.13%  |
| 参数量       | 2.59 M      | 41.0 M      | -38.41 M |
| 计算量       | 6.4         | 125.3       | -118.9   |
| 推理速度(FPS) | 72          | 15          | +57      |
| 收敛轮次      | 约 100 轮趋于稳定 | 180 轮达到最优   | -        |

结果表明, YOLO11 在各项核心指标上全面优于 Faster R-CNN。YOLO11 最优 mAP50 达 94.80%, 精确率 96.30%, 召回率 89.60%, F1 分数 92.85%, 参数量仅 2.59 M, 计算量仅 6.4 GFLOPs, 推理速度达 72 FPS, 在有限样本条件下实现了检测精度与实时性的优异平衡。

#### 3.2. 各类缺陷检测性能对比与可视化分析

两种算法对不同缺陷类别的单类 AP 检测性能如表 3 所示。

**Table 3.** AP comparison of each type of hidden danger  
**表 3.** 各类隐患单类别 AP 对比

| 缺陷类别         | YOLO11 AP | Faster-RCNN AP | 性能差异    |
|--------------|-----------|----------------|---------|
| 鼓包(bulge)    | 94.20%    | 92.19%         | +2.01%  |
| 坍塌(collapse) | 97.40%    | 93.11%         | +4.29%  |
| 裂缝(crack)    | 92.80%    | 60.43%         | +32.37% |
| mAP50        | 94.80%    | 81.91%         | +12.89% |

两种算法对坍塌缺陷的检测效果相对较好, 因其缺陷特征明显、区域较大, 易被模型识别; 裂缝缺陷多为细长低对比度特征, 检测难度最高。YOLO11 在裂缝缺陷上提升尤为明显, 体现出单阶段模型在有限样本下对弱特征的学习优势。

选取测试集中 4 组具有代表性的采煤工作面隐患图像(对应子图(a)~(d)), 开展 YOLO11 与 Faster R-CNN 的检测效果可视化对比, 直观呈现两类模型在井下复杂场景下的实际检测差异, 见图 3。两类模型的对比检测结果如图 3 所示, 其中 YOLO11 以青色框标注裂缝(crack)、白色框标注鼓包(bulge)、蓝色框标注坍塌(collapse), 并标注目标类别与置信度; Faster R-CNN 以绿色框标注裂缝(crack)、蓝色框标注鼓包(bulge)、红色框标注坍塌(collapse), 区分三类隐患的检测结果。


结合图3中上下两部分检测结果, 两类模型的性能差异可归纳为以下三点:

(1) 针对细长型、低对比度裂缝(crack)目标: YOLO11 可完整覆盖裂缝区域, 青色边界框与目标轮廓高度贴合, 输出置信度稳定(如子图(a)、(d)中的裂缝目标); Faster R-CNN 对裂缝类小目标存在明显漏检, 已检出目标的绿色边界框贴合度差、定位精度不足, 且出现大量冗余检测框。


(2) 针对鼓包(bulge)、坍塌(collapse)等大尺度隐患目标: YOLO11 的白色/蓝色检测框定位精准, 误检与冗余框数量少, 置信度分布均匀(如子图(b)、(c)中的鼓包、坍塌目标); Faster R-CNN 虽可完成大尺度目标的基础检测, 但蓝色/红色框体存在置信度偏低、框体冗余、定位偏移等问题, 检测可靠性显著弱于 YOLO11。

(3) 针对井下复杂环境下的弱特征目标: YOLO11 在低光照、强背景干扰的场景中, 仍能稳定识别三类隐患, 泛化能力突出; Faster R-CNN 受井下环境噪声影响显著, 漏检、误检现象频发, 难以适配采煤工作面的复杂检测场景。

图3的可视化结果清晰表明, YOLO11 相比 Faster R-CNN 在采煤工作面复杂井下环境中的检测效果提升显著。该模型不仅有效改善了裂缝类小目标的漏检问题, 还大幅增强了对低光照、低对比度、弱特征目标的泛化能力与实用性, 充分验证了 YOLO11 在采煤工作面隐患检测任务中的有效性与优越性。



YOLO 检测结果





Faster R-CNN 检测结果


**Figure 3.** Comparison of coal mine hidden danger detection results between YOLO11 and Faster R-CNN; Upper part: YOLO11 detection results; Lower part: Faster-RCNN detection results

**图 3.** YOLO11 与 Faster R-CNN 煤矿缺陷检测效果对比图；上半部分：YOLO 检测结果；下半部分：Faster-RCNN 检测结果

### 3.3. 训练过程分析

YOLO11 模型完整训练损失变化曲线见图 4。YOLO11 模型在训练初期(0~25 轮)收敛速度极快，训练损失与验证损失同步快速下降，可高效学习缺陷基础特征；中期(25~100 轮)损失曲线平稳下降，仅在 50 轮左右因 Mosaic 增强关闭出现小幅波动，整体训练过程稳定；后期(100~200 轮)损失缓慢下降并趋于收敛，训练损失与验证损失始终保持合理差距，未出现明显过拟合，在有限样本场景下具备优异的稳定性与泛化性。

Faster R-CNN 整体收敛周期更长，前期特征学习速度显著低于 YOLO11，在相同训练策略下，模型对隐患特征的利用效率相对有限，最终在验证集上的泛化性能弱于 YOLO11。尽管 Faster R-CNN 在训练集上可实现充分拟合，但其在有限样本条件下对小目标、弱特征的学习能力仍有不足，最终 mAP50 显著低于 YOLO11，损失曲线见图 5。



**Figure 4.** Training and validation loss curve of YOLO11 model

**图 4.** YOLO11 模型训练与验证损失曲线




Figure 5. Training and validation loss curve of Faster R-CNN model  
图 5. Faster R-CNN 模型训练与验证损失曲线

对比两模型损失曲线可知:YOLO11 采用单阶段端到端训练方式,全程损失平滑下降、无剧烈震荡,收敛速度快且稳定性强,最终训练损失与验证损失均稳定在 0.9~1.0 区间;Faster R-CNN 受两阶段训练策略影响,前期特征学习缓慢,全程损失下降幅度远小于 YOLO11,最终训练损失稳定在 2.1 左右、验证损失稳定在 3.0 左右,训练稳定性弱于 YOLO11。尽管 Faster R-CNN 训练集拟合程度更高,但在有限样本场景下对缺陷特征的泛化能力仍显不足,最终 mAP50 仅为 81.91%,远低于 YOLO11 模型的 94.80%,充分体现了单阶段 YOLO 模型在工业有限样本缺陷检测任务中的优越性。

3.4. 结果讨论

本次实验在统一硬件环境、相同数据增强策略、统一优化器类型的前提下开展,针对单阶段与两阶段模型的结构差异采用官方适配的最优超参数,确保两种模型均发挥最佳性能,实验设计符合目标检测领域算法公平对比规范。YOLO11 在有限样本煤矿隐患检测中表现更优,主要得益于单阶段端到端结构对样本的利用效率更高,轻量化结构配合自适应学习率可实现快速收敛,对细长、低对比度裂缝等微弱特征的提取能力更强,同时模型参数量小、计算量低、推理速度快,更适配井下实际部署需求。Faster R-CNN 检测精度相对较低,主要原因在于两阶段结构对样本规模依赖性更高,有限样本下难以充分学习隐患特征,且模型体量更大、计算量更高、推理速度较慢,对小目标、弱特征隐患的检测鲁棒性相对较弱。

3.5. 独立测试集泛化验证

Table 4. Model performance indicators on independent test set  
表 4. 独立测试集模型性能指标

| 评价指标   | YOLO11 (测试集) | Faster R-CNN (测试集) |
|--------|--------------|--------------------|
| mAP50  | 76.85%       | 73.14%             |
| 精确率(P) | 93.35%       | 40.59%             |
| 召回率(R) | 67.88%       | 73.14%             |
| F1 分数  | 78.47%       | 52.21%             |

为进一步验证模型在真实井下场景的泛化能力,采用全程独立隔离、未参与训练与参数调优的测试集进行客观评估,实测指标如表 4 所示。

结果显示,YOLO11 在测试集上 mAP50 为 76.85%、精确率 93.35%、召回率 67.88%、F1 分数 78.47%;Faster R-CNN 在测试集上 mAP50 为 73.14%、精确率 40.59%、召回率 73.14%、F1 分数 52.21%。独立测试集结果表明,YOLO11 与 Faster R-CNN 的性能趋势与验证集保持一致,YOLO11 在精确率上显著优于 Faster R-CNN,表明其误检率更低,在实际井下预警中可有效减少无效告警对操作人员的干扰。值得注意的是,YOLO11 在测试集上的召回率略低于 Faster R-CNN,分析原因在于测试集中部分裂缝样本对比度极低、背景干扰严重,YOLO11 为维持高精确率采用了较严格的置信度阈值,导致少量困难样本被漏检。尽管如此,YOLO11 的综合 F1 分数仍高于 Faster R-CNN,整体检测可靠性更优。尤其对于裂缝、鼓包等小目标隐患,YOLO11 保持了更高的检出完整性与定位精度。综上,验证集与独立测试集的双重结果一致证实:在有限样本、复杂背景的采煤工作面隐患检测任务中,YOLO11 比 Faster R-CNN 具有更强的泛化能力和工程部署价值。

#### 4. 结论与建议

采煤工作面隐患目标检测场景中,经独立测试集泛化验证,YOLO11 算法的综合性能优于 Faster R-CNN;YOLO11 在测试集上的 mAP50 为 76.85%、精确率 93.35%、召回率 67.88%、F1 分数 78.47%,在验证集上的最优 mAP50 达 94.80%、精确率 96.30%、召回率 89.60%、F1 分数 92.85%,模型参数量仅 2.59 M、计算量 6.4 GFLOPs、推理速度 72 FPS,收敛速度快、稳定性好、实时性强,值得注意的是 YOLO11 在测试集上的召回率略低于 Faster R-CNN,但其精确率远高于后者,在实际井下预警中可显著减少无效告警,综合 F1 分数更优,因此更适配井下工程应用;Faster R-CNN 经 200 轮训练后验证集 mAP50 为 81.91%、测试集 mAP50 为 73.14%,可实现部分隐患检测,但存在收敛周期长、模型体量大、推理速度慢、对小目标漏检明显等问题,在井下复杂环境下适用性有限。综合来看,在样本有限、环境复杂的煤矿井下场景中,YOLO11 在检测精度与实时性方面优势突出,可作为采煤工作面隐患实时检测的优选方案;基于本研究结果,建议采煤工作面隐患检测优先选用 YOLO11 系列模型,在保障检测精度的同时降低训练与部署成本,数据扩充重点聚焦裂缝类小目标样本以进一步提升模型适应能力,若采用 Faster R-CNN 可结合轻量化改进与迁移学习提升模型效率,后续结合嵌入式平台优化技术推动优选模型在井下智能监测装备中的落地应用。

#### 基金项目

廊坊市科学技术研究与发展计划自筹经费项目(2026011037);中央高校基本科研业务费专项资金资助项目(3142024039)。

#### 参考文献

- [1] Ren, S., He, K., Girshick, R. and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/tpami.2016.2577031>
- [2] 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>
- [3] 程德强, 钱建生, 郭星歌, 寇旗旗, 徐飞翔, 顾军, 高亚超, 赵金升. 煤矿安全生产视频 AI 识别关键技术研究综述[J]. 煤炭科学技术, 2023, 51(2): 349-365.
- [4] 李志星, 杨啸龙, 李天昊, 王宁宁. 基于 YOLOv8 的煤矿用钢丝绳损伤检测算法[J]. 电子测量技术, 2024, 47(9): 120-128.

- [5] 寇发荣, 肖伟, 何海洋, 陈若晨. 基于改进 YOLOv5 的煤矿井下目标检测研究[J]. 电子与信息学报, 2023, 45(7): 2642-2649.
- [6] 叶鸥, 窦晓熠, 付燕, 邓军. 融合轻量级网络和双重注意力机制的煤块检测方法[J]. 工矿自动化, 2021, 47(12): 75-80.
- [7] 李波, 王奕鸣, 袁鹏喆, 杨帆. 煤矿井下监控图像去噪算法研究[J]. 工矿自动化, 2026, 52(5): 128-136.
- [8] 景宁波, 徐子骏, 潘红光, 秦学斌, 雷心宇, 米文毓, 石珂珂. 基于改进 YOLOv11 的煤矿井下人员安全帽佩戴检测方法[J]. 工矿自动化, 2026, 52(5): 119-127.
- [9] 张瑞圆, 曹现刚, 马宏伟, 王岩. 煤矿装备运维领域大语言模型指令数据集构建方法[J]. 西安科技大学学报, 2026, 46(4): 804-816.