

基于深度学习的安检管制物品识别研究

严伟

西南交通大学, 四川 成都 611756

DOI:10.61369/RSTD.2026020007

摘要: 传统安检依靠人工判读 X 光图像, 易受疲劳、物品遮挡与伪装影响, 出现漏检、误检, 难以满足现代安检高效精准的需求。本文基于深度学习构建安检管制物品识别方法, 以 YOLOv8 为核心检测模型, 通过数据预处理、超参数调优与损失函数改进完成模型训练与优化。实验结果表明, 该模型在测试集上准确率达 75.2%, 召回率为 57.2%, 可在复杂场景下有效识别管制物品, 提升安检效率与检测精度, 为公共安全智能化提供技术支撑。

关键词: 深度学习; YOLOv8; 管制物品识别; X 光安检; 目标检测

Research on Security Inspection and Control of Items Based on Deep Learning

Yan Wei

Southwest Jiaotong University, Chengdu, Sichuan 611756

Abstract: Traditional security checks rely on manual interpretation of X-ray images, which are susceptible to fatigue, item occlusion, and camouflage, resulting in missed detections and false detections, and are unable to meet the efficient and precise requirements of modern security checks. This paper constructs a security check control item recognition method based on deep learning, with YOLOv8 as the core detection model. Through data preprocessing, hyperparameter tuning, and loss function improvement, the model training and optimization are completed. Experimental results show that the model achieves an accuracy rate of 75.2% and a recall rate of 57.2% on the test set. It can effectively identify control items in complex scenarios, improve security check efficiency and detection accuracy, and provide technical support for the intelligence of public security.

Keywords: deep learning; YOLOv8; control item recognition; X-ray security check; object detection

引言

当前主流安检方式仍以人工目视判读 X 光图像为主, 该模式对操作人员专业要求高、劳动强度大, 长时间作业易引发视觉疲劳, 导致漏检与误检率偏高。相关数据显示, 在物品重叠、遮挡复杂的图像中, 人工安检误检率可达 15%—20%, 严重影响安检可靠性, 无法适应现代交通与重点场所对安检效率与安全性的要求。在此背景下, 基于 YOLOv8 开展安检管制物品智能识别研究具有重要实用价值。该方法凭借检测速度快、定位精度高的特点, 可自动识别多类违禁物品, 降低人为失误, 缩短候检时间, 提升安检通行效率。从行业发展来看, 将深度学习引入安检领域, 能够推动传统安检向智能化升级, 带动相关算法与设备创新, 提高行业整体技术水平, 更好满足公共安全保障需求。

一、模型选择与结构

(一) 模型选择

安检 X 光图像管制物品检测, 要求模型具备精准定位、抗遮挡、多尺度检测与快速部署能力。YOLO 系列单阶段检测模型可高效处理高分辨率图像, 支持多目标并行识别, 对物品角度变化、堆叠遮挡适应性强, 且采用端到端输出结构, 可同时给出目标类别与位置信息, 工程部署便捷, 能够满足安检实时检测需求。

(二) Yolov8 模型

YOLOv8 是在 YOLOv5 基础上改进的新一代目标检测模型, 主要有两点关键升级: 检测头采用主流的解耦头设计, 将分类

与定位分支分开, 提升收敛速度与检测精度; 同时改用无锚框 (Anchor-Free) 检测机制, 直接在每个网格预测目标中心点偏移与宽高, 无需预先设定锚框尺寸, 减少超参数数量, 简化训练与推理流程, 提升小目标与密集目标检测效果。

二、实验过程

(一) 实验数据集

本文采用 Kaggle 公开安检 X 光数据集, 共 3600 张图像, 涵盖刀具、打火机、压力容器、易燃易爆品等常见管制物品。按照 85%、10%、5% 划分为训练集 3060 张、验证集 360 张、测试集

180 张，总标注框 9042 个。




图 2.1 数据集样式

如表 2.1 所示按照 85%、10%、5% 的比例构建训练集、验证集与测试集，其中用于模型训练的训练集、用于模型参数调整和性能评价的验证集以及用于最终模型性能测试的测试集。

表 2.1 数据集概览

数据集	图片总数	标注框总数
Train	3060	7666
Val	360	917
Test	180	459
总计	3600	9042

数据整体汇总统计如表 2.2 所示，其中训练对应的中文类别：“气体”：0，“打火机”：1，“充电宝”：2，“刀”：3，“弹弓”：4，“剪刀”：5，“手铐”：6，“拉链”：7，“指甲油”：8，“鞭炮”：9。

表 2.2 整体汇总统计

类别 ID	类别名称	总标注框数	总包含图片数
0	Pressure	1080	807
1	Lighter	2529	1584
3	Knife	2858	1412
4	Slingshot	132	114
5	Scissors	744	666
6	Handcuffs	275	241
7	Zippooil	301	267
8	Nailpolish	85	46
9	firecrackers	141	95

(二) 数据采集和预处理

1 数据采集

数据来源包括真实安检扫描、实验室模拟拍摄、3D 结构信息采集及公开数据集扩充。通过多场景、多角度、多包裹方式采集图像，保证样本多样性。为适配模型输入，对图像进行尺寸统一、亮度归一化与空间变换处理。

2 数据标注

使用 Labelimg 工具对目标物品进行人工标注，明确类别与边界框，确保标注规范统一，减少标注误差对模型训练的影响。

3 数据清洗与增强

先剔除模糊、缺损、标注错误的无效样本，再通过翻转、旋转、缩放、加噪等方式进行数据增强，提升模型在不同姿态、遮挡条件下的泛化能力。

(三) 模型配置与训练

1 模型配置

基于 Python 搭建训练环境，关键超参数如下：初始学习率 0.01，学习率衰减 0.01，动量 0.937，权重衰减 0.0005，热身轮数 3.0，批次大小 16，输入尺寸 640。在保证收敛速度的同时降低过拟合风险。

表 2.3 关键超参数及其设定

超参数	设置	说明
学习率 (lr0)	0.01	决定了模型权重调整的步长大小，在训练初期有助于快速收敛
学习率衰减 (lrf)	0.01	控制训练过程中学习率的降低速度，有助于模型在训练后期细致调整
动量 (momentum)	0.937	加速模型在正确方向上的学习，并减少震荡，加快收敛速度
权重衰减 (weight_decay)	0.0005	防止过拟合，通过在损失函数中添加正则项减少模型复杂度
热身训练周期 (warmup_epochs)	3.0	初始几个周期内以较低的学习率开始训练，逐渐增加到预定学习率
批量大小 (batch)	16	每次迭代训练中输入模型的样本数，影响 GPU 内存使用和模型性能
输入图像大小 (imgsz)	640	模型接受的输入图像的尺寸，影响模型的识别能力和计算负担

2 模型训练

加载 YOLOv8 预训练权重，设置训练轮数 200 轮，启动训练并实时监控损失、精度、召回率等指标。训练完成后模型可自动定位并分类 X 光图像中的管制物品。

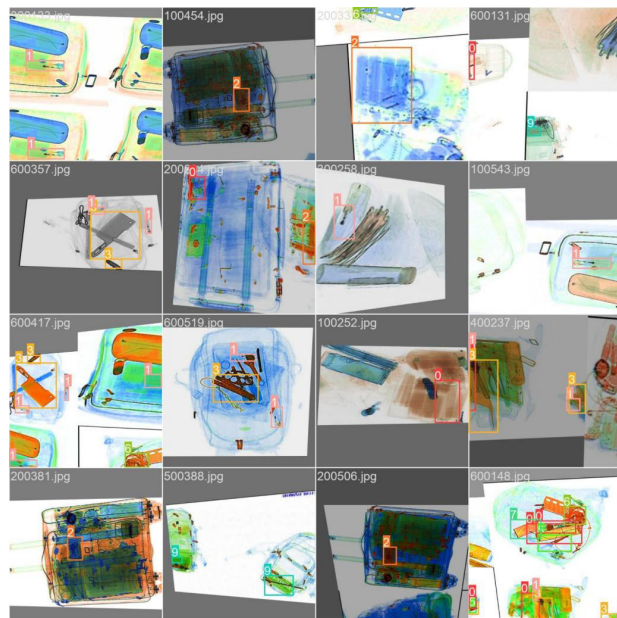


图 2.4 训练后的图像

三、实验结果分析

(一) 模型训练结果

训练过程中损失曲线快速下降，模型收敛良好。混淆矩阵显示，打火机、气体容器等物品识别效果较好，弹弓、剪刀等特征相近物品存在一定误判，主要由 X 光图像纹理相似、小目标特征提取不足导致。

置信度曲线表明，综合 F1 值在置信度 0.366 时达到 0.63；精确率随置信度升高而上升，0.941 时达 1.00；召回率随置信度升高逐步下降，0 置信度时为 0.83。在 IoU=0.5 下，模型整体 mAP 为 0.642，具备实际应用价值。




图 3.1 训练图表

1. 混淆矩阵

在目标检测任务中，对模型性能进行混淆矩阵分析是评价的关键步骤之一。如图 4.2 所示模型对不同物品的辨识能力有明显差异，如打火机、压力容器等部分物品有一定正确识别数，但也存在误判；弹弓、剪刀等物品正确识别少，误判严重。其中物品间以及物品与背景存在双向误判，背景常因纹理等被误认成物品，物品也会被错判为背景。这主要源于模型对部分物品特征提取不足，以及 X 光图像中物品特征相似干扰判断。

在基于深度学习的安检管制物品识别系统设计中，混淆矩阵通过直观的 n 行 n 列的矩阵形式来表示，它提供了定量衡量模型在分类任务中表现的手段。每个列代表模型预测类别和每个列表表示实际类别，混淆矩阵使本系统在性能评价方面将各类的正确和错误分类情况量化以达到对模型整体性能的认识。混淆矩阵可以计算每个类别的精度和召回率，这两个指标分别反映了模型预测的准确性和完整性，精度高意味着模型在预测某一类别时，大部分预测该类别的样本确实属于该类别，而召回率高意味着该类别的样本大多数被模型正确识别。

错误分析是混淆矩阵的应用之一，其展示了模型在特定类别的混淆情况，从中了解模型存在的问题，如对某些具有相似特征的个体识别困难等，这有助于改进模型泛化能力；还可以用于解决数据不平衡问题，不同个体在目标检测任务中的样本量会存在明显差异，这容易造成模型偏向多数类，想解决这些问题可以通过分析混沌矩阵识别少数类来针对问题采取如重、调整类别权重等措施。




图 3.2 混淆矩阵

2.F1- 置信度曲线

F1 - Confidence 曲线图展示了安检管制物品识别中不同类别

物品及所有类别综合的 F1 值随置信度变化的情况。如图 4.3 所示所有曲线均呈现出 F1 值随置信度增加先上升后下降的趋势，过高的置信度导致召回率显著下降，使得 F1 值降低。

深蓝色的合成曲线代表所有类别，在置信度为 0.366 的情况下，所有类别合成的 F1 数值达到了 0.63，这体现了模型在识别各种管制物品时的综合表现。模型对不同管制物品的辨识表现有明显差异，后续需要从增加数据量、优化特征提取、调整模型结构、确定合适的置信度阈值、提高安检辨识效率和准确性等方面改进，以提升模型对各类管制物品的辨识整体表现。




图 3.3 F1- 置信度曲线

3. 准确率 - 置信度曲线

Precision - Confidence 曲线展示了安检管制物品识别中不同类别物品及所有类别综合的精确率随置信度变化的情况。如图 4.4 所示各条曲线在上升的同时，也呈现出伴随着精确率的可靠度提升的态势。这是因为在置信度较低时，模型会输出较多预测结果中包含不少错误预测，导致精确率低；随着置信度升高，模型仅保留更可靠的预测，精确率得以提升。

深蓝色的综合曲线代表所有类别，在置信度达到 0.941 时，所有类别综合的精确率达到 1.00，反映了模型对各类管制物品识别的综合精确率表现。




图 3.4 准确率 - 置信度曲线

4. 召回率 - 置信度曲线

Recall - Confidence 曲线用于呈现安检管制物品识别中不同类别物品及所有类别综合的召回率随置信度变化的情况。如图 4.5 所示各条曲线随着信心的提升，呈现出回调幅度递减的态势。这是因为置信度较低时，模型会输出更多检测结果，能涵盖更多真实目标，召回率较高；但随着置信度升高，模型筛选条件变严，输出结果减少，导致召回率降低。

深蓝色的复合曲线代表所有类目，在置信度 0.000 的情况下，所有类目的复合召回率为 0.83，反映了模型综合召回率在检测各种管制物品时的表现。




图 3.5 召回率 - 置信度曲线

5. 准确率 - 召回率曲线

Precision - Recall 曲线用于评估安检管制物品识别中不同类别物品以及所有类别综合的检测性能。如图 3.6 所示从曲线的整体趋势来看，各物品的精确率都随着召回率的增加而下降，这是因为当模型试图提高召回率时，往往会放宽检测条件，从而导致精确率降低。

深蓝色的综合曲线代表所有类别，在 IoU 阈值为 0.5 时，所有类别综合的平均精度均值 mAP 为 0.642，反映了模型对各类管制物品检测性能的整体水平。




图 3.6 准确率 - 召回率曲线

(二) 实验结果

所得验证集 (val) 标注结果如图 3.7 所示，模型对各类别进行标注和类别注释。



图 3.7 val 标注结果

经过多轮的培训和优化，最终培训获得的 YOLOV8 模型在测试集中取得了优异的成绩。实验结果表明，该模型在安检控制物品识别任务中准确率达到 75.2%，召回率达到 57.2%，MAP 达到 0.65，与传统的基于人工判读的安检方式相比，系统在识别准确率和识别效率方面都有明显提高。在实际的安检场景测试中，系统可以在短时间内处理大量的安检图像，对被控制物品进行准确检测，使安检人员的工作负担大大减轻，效率和准确度也有所提高。

四、结论

本文针对安检管制物品智能识别需求，构建基于 YOLOv8 的深度学习检测方案。通过多源数据采集、规范标注、清洗增强构建高质量数据集；通过超参数优化、训练策略改进提升模型性能，避免过拟合与欠拟合。实验表明，该模型可有效识别刀具、易燃易爆品、压力容器等多类管制物品，在精度与速度上达到平衡，能够辅助人工提升安检效率与可靠性。未来可通过扩大数据集、优化特征提取网络、引入多模态信息等方式，进一步提升对小目标、遮挡目标的识别能力，推动智能安检技术落地应用。

参考文献

- [1] 杨子固. 基于深度学习的 X 光安检图像危险品识别方法研究 [D]. 太原理工大学, 2021. DOI: 10.27352/d.cnki.gylgu.2021.000167.
- [2] 朱昊. 基于深度学习的 X 光安检违禁品检测算法研究 [D]. 东北林业大学, 2024.
- [3] 杨钧彦. 基于深度学习的安检危险物品识别技术研究 [D]. 杭州电子科技大学, 2024.
- [4] 叶亚林, 谢连军, 高丙朋, 等. 改进 YOLOv7-Tiny 的 X 射线安检违禁品检测 [J]. 科学技术与工程, 2024, 24(26): 11349-11357.
- [5] 钟健. 基于卷积神经网络的安检 X 光图像检测识别方法研究 [D]. 江西理工大学, 2024. DOI: 10.27176/d.cnki.gnfy.2024.000405.
- [6] 黄显宁. 基于深度学习的 X 光透射图像安检违禁品检测研究 [D]. 云南师范大学, 2024. DOI: 10.27459/d.cnki.gynfc.2024.001077.
- [7] 周泽玮. 基于深度学习的 X 光安检违禁品检测研究 [D]. 广州大学, 2024. DOI: 10.27040/d.cnki.ggzdu.2024.000549.