

doi:10.3969/j.issn.1673-9833.2025.01.010

一种面向交通安全的违禁品轻量级检测方法

翁成康, 黄贤明, 黄海洋

(湖南工业大学 计算机学院, 湖南 株洲 412007)

摘要: 针对X光安检图像中摆放杂乱、故意遮挡、小型不规则物品检测等问题,以及安检工作对实时性、快速性的要求,基于YOLO v5s网络模型提出了一种结合改进的轻量级实时违禁品监测方法LRCD,以辅助安检人员快速进行检测。通过在模型的主干中使用DenseOne模块替代YOLO v5s主干中的C3模块,进而丰富特征,提高网络的特征表达能力;为了提高推理速度,使用SimSPPF替换YOLO v5s主干中的SPPF;同时引入WIoU(Wise-IoU)损失函数,抑制了冗余特征对检测网络的影响,增强了网络获取违禁品中包含的多尺度特征的能力。在针对X光下行李物品图片的EDS数据集中进行测试, mAP 达68.96%, FPS 达136.9,对比近年来被广泛使用的其他经典目标检测模型,分别平均提升了6.35%与66.7%。

关键词: 轻量化; 卷积神经网络; X光图像; 注意力机制; 违禁品检测

中图分类号: TP391

文献标志码: A

文章编号: 1673-9833(2025)01-0072-07

引文格式: 翁成康, 黄贤明, 黄海洋. 一种面向交通安全的违禁品轻量级检测方法[J]. 湖南工业大学学报, 2025, 39(1): 72-78.

A Lightweight Detection Method of Contraband Aimed at Traffic Safety

WENG Chengkang, HUANG Xianming, HUANG Haiyang

(College of Computer Science, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the flaws of disorderly placement, intentional obstruction, and detection of small irregular items in X-ray security inspection images, as well as the requirements for real-time and fast security inspection purpose, a lightweight real-time contraband detection method (LRCD) has thus been proposed based on YOLO v5s network model to assist security personnel in rapid detection. By replacing the C3 module in the YOLO v5s backbone with the DenseOne module in the model backbone, the features can be enriched and the network's feature expression ability can be improved; with SPPF(spatial pyramid pooling-fast) in YOLO v5s backbone replaced with SimSPPF for an improvement of the inference speed. Meanwhile, the WIoU (Wise IoU) loss function is introduced for an suppression of the influence of redundant features on the detection network, thus enhancing the network's ability to obtain multi-scale features contained in contraband goods. In the EDS (endogenous domain shift) dataset for X-ray images of luggage and items, the mAP (mean average precision) reaches 68.96% and FPS reaches 136.9. Compared with other widely used classic object detection models in recent years, the average improvements can be as high as 6.35% and 66.7%, respectively.

收稿日期: 2024-03-24

基金项目: 教育部中国高校产学研创新基金资助项目(2020ITA05043); 湖南省教育厅科学研究基金资助项目(21C0409, 2023DT002)

作者简介: 翁成康, 男, 湖南工业大学硕士生, 主要研究方向为深度学习, 计算机视觉, 目标检测,

E-mail: chengkang_weng@163.com

通信作者: 黄贤明, 男, 湖南工业大学副教授, 硕士生导师, 主要研究方向为大数据技术, 知识图谱, 教育信息化,

E-mail: 841619296@qq.com

Keywords: lightweight; convolutional neural network; X-ray image; attention mechanism; contraband detection

1 研究背景

随着中国基础设施建设的不断完善, 运输安全已成为人们关注的重点领域。目前检测违禁品的主流方法是安检人员通过观察行李物品的 X 光图像, 判断其是否属于违禁品^[1]。虽然 X 光安检仪已被广泛应用于世界上大多数的交通枢纽^[2], 但 X 光下违禁品人工检查^[3]的准确度在长时间、高强度的工作环境下会持续降低。因此, 将检测与计算机视觉技术结合, 从 X 光图像中自动识别并标注行李中的违禁物品, 辅助安检人员进行安检, 是未来发展的必然趋势。

计算机视觉是将生物对客观世界的识别和理解用计算机实现的技术。目标检测是计算机视觉的一个重要分支和应用, 其目标类似于在图像或视频中检测和定位人、车、动物等对象实例。根据检测过程是否产生锚框 (Anchor), 目标检测算法可以被分为两类, 即 Anchor-based 算法与 Anchor-free 算法。在主流检测模型中, Tan M. X. 等^[4]于 2020 年推出的 Efficientdet 模型使用多尺度 Anchor 框, 在不同的特征级别为检测提供不同大小的先验框, 有助于检测不同尺度对象。YOLO 系列也采用 Anchor 框作为检测先验, 在每个特征点上上进行多类别与多尺度的检测。Zhu X. 等^[5]的 YOLO v5、Ge Z. 等^[6]的 YOLOX 在 Anchor 框的数量选择和尺度设计上进行改进, 以实现最佳的速度和准确率。相比之下, Zhou X. 等^[7]于 2019 年提出的 CenterNet 没有使用 Anchor 框, 它通过中心点回归方案实现目标检测, 并使用基于关键点的特征表达方式, 通过组件损失函数精确预测对象中心, 实现了高精度检测。不同的目标检测算法各有优势: Anchor 框提供的先验信息有助于检测, 也限制了模型的自由度; Anchor-free 方式更加自由, 但训练难度较大。

针对 X 光行李物品安全检测中存在的问题^[8], 国内外的研究人员提出了众多解决思路。郭守向等^[9]在单阶段目标检测网络 YOLO v3 的基础上, 结合复合骨干网络思想, 构建了 YOLO-C 目标检测网络, 提升了检测的鲁棒性。针对卷积神经网络训练过程中存在的数据缺乏问题^[10], Zhu Y. 等^[11]利用数据增强方法, 将非 X 光下图像转化为类似 X 光下图像, 并与不同背景组合, 获得了用于模型训练的数据。然而, 这些工作未考虑到违禁品不规则的纵横比对模型训

练以及预测的影响。同时由于安检机的运行速度非常快, 为了保证检测的效率, 需要进一步提升识别标注违禁品的速度。

基于上述工作带来的启发, 课题组针对 X 光下行李物品中违禁品检测的速度问题, 在保证检测精度的前提下, 使用了简化的空间金字塔池化方法, 进而提升了方法的推理速度。为了解决 X 光图像中存在的物品摆放杂乱、故意遮挡等问题, 使用 DenseOne 模块^[12]替代 YOLO v5s 主干中的 C3 模块, 在保证信息流通的同时丰富特征, 提高网络的表达能力。同时通过引入新的损失函数, 增强了方法对物品多尺度特征的提取能力, 解决 X 光下图像中存在的小型与不规则物品检测难题。在针对 X 光下行李物品的 EDS (endogenous domain shift) 数据集^[13]上的实验结果显示, 设计的算法实现了最高的检测精度与速度。

2 原理与设计

LRCD (lightweight real-time contraband detection) 方法基于 YOLO v5s 方法改进, 基本结构如图 1 所示, 主要由高速违禁品检测网络 (high speed contraband detection network, HSCDNet) 和融合检测头 (fusion detection head, FD-Head) 两部分组成。

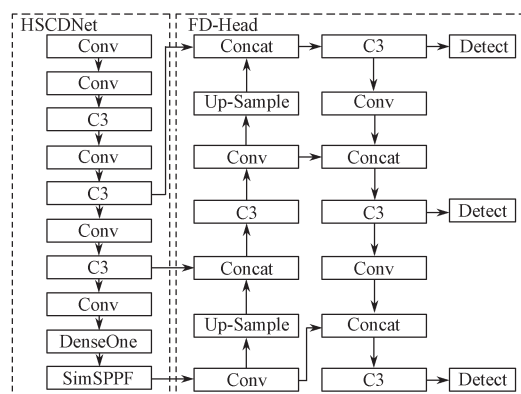


图 1 LRCD 的整体结构

Fig. 1 Overall structure of LRCD

HSCDNet 部分是实现定位、检测和分割的基石。它通过卷积与池化等操作抽取输入数据的高层语义特征, 然后对这些特征进行提炼与压缩^[14], 主要由卷积模块、C3 模块和空间金字塔池化模块组成。输出包含数据关键信息的特征图, 为后续任务提供输入。还可以为任务提供先验信息, 实现参数的共

享与初始化。FD-Head 结构利用检测模块和损失函数来确定目标的分类和定位,实现目标检测。使用 DenseOne 模块替代原有主干中的 C3 模块,增强了网络对模糊和隐藏违禁品的学习能力,在保证信息流通的同时丰富特征,提高网络对违禁品图像的特征表达能力,从而增强网络模型对目标的识别能力。

2.1 DenseOne 模块

DenseOne 模块来源于 Huang G. 等^[12]的 DenseNet,它采用类似于跳跃连接(skip connection)的结构,即每个层都会接受其前面所有层作为其额外输入,如图 2 所示。

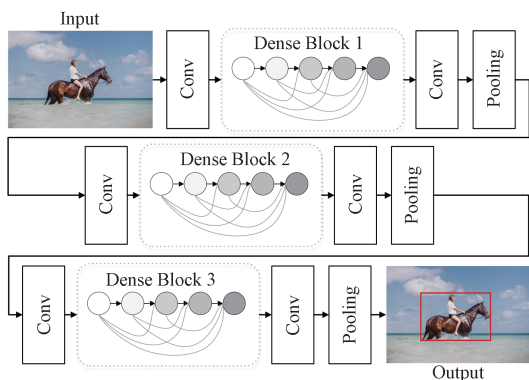


图 2 DenseNet 结构示意图

Fig. 2 Structure diagram of DenseNet

在采用跳跃连接的网络中,会将前层的输出通过残差块传递给后层,保留前层特征的同时,后层只需要学习输入和输出的差异即可。这种结构可以加速网络的训练,并提高层次复杂神经网络的性能。跳跃连接最初由 He K. M. 等^[15]在 ResNet 网络中首次提出,它已经成为构建更好深层神经网络的常用技巧之一。

与传统跳连不同的是, DenseOne 将前层的所有特征图与当前层的特征图进行拼接,使得每层特征图的维度更大,这也是 DenseOne 名称中“One”所表达的含义,即“一个额外的特征”。而这样的设计在保证信息流通的同时加强了特征提取,也有利于训练深度神经网络时缓解梯度消失问题。

2.2 SimSPPF 模块

SimSPPF (simplified spatial pyramid pooling-fast) 由 Li C. 等^[16]在 SPPF (spatial pyramid pooling-fast)^[5]的基础上简化而成,结构如图 3 所示。




图 3 SimSPPF 模块详细结构

Fig. 3 Detailed structure of SimSPPF blocks

相比于普通的 SPPF 模块, SimSPPF 去除了低分辨率特征提取分支,只保留高分辨率分支。这简化了模块结构,减少了参数量。同时通过调整通道数,保证 SimSPPF 参数量与原 SPPF 模块相当,从而不影响表达能力。

SimSPPF 的参数量和计算量大幅减小,运算速度更快,更适合在违禁品检测领域中应用。其中卷积单元(conv unit, CU)由卷积(Conv)层、批标准化(batch normalization, BN)层^[17]以及整合线性单元(rectified linear unit, ReLU)组成。卷积层用于提取输入的低层特征,得到特征图。BN 层用于标准化每一层的特征图,加快了模型收敛速度,增强了模型泛化能力。ReLU 用于引入非线性,增强网络对复杂函数的表达能力。另外将 BN 置于激活函数之前,因为 BN 能减小输入的偏移,使激活函数工作在最优区域,可有效避免梯度消失问题,防止过拟合。

2.3 非极大值抑制算法

非极大值抑制算法(non-maximum suppression, NMS)^[18]是目标检测中的一种常见的后处理技术,可用于抑制掉重复的检测框,并只保留置信度最高的检测框^[19]。如今大部分的 One-Stage 和 Two-Stage 算法在推断阶段都使用了 NMS 作为网络的最后一层,例如 SSD^[20]、Faster-RCNN^[21]等。

NMS 算法的基本思想,是在所有检测框中,首先选出置信度最高的检测框,然后计算其余检测框与该检测框的交并比(intersection over union, IoU),如果 IoU 值超过了预设阈值,则将这些检测框抑制掉。NMS 的本质是搜索局部极大值,其在目标检测中,经常被用于消除多余的检测框。NMS 有很多种变体,最为常见的为 Hard-NMS。但是 Hard-NMS 会直接删除相邻的同类别目标,对密集目标的输出不友好,而 X 光行李物品常呈现出一种密集、层叠的状态。因此,应当选取一种更为先进的 NMS 方式用于抑制多余的检测框。

Merge-NMS^[22]是 NMS 算法的一种变体,与传统 NMS 不同的是, Merge-NMS 在 Hard-NMS 的基础上,增加了保留框位置平滑策略(即重叠框位置信息求解平均值),因此它不仅能够抑制掉重复的检测框,而且还能将相邻的检测框合并成一个更精确的检测框。对于一批重复率较高的框,根据置信度赋予每个预测框一个权重值,置信度较高的权重也较高,则有理由更加看重这个预测框。处理好这批相识度较高的预测框之后,继续处理当前类别的下一批预测框,如此循环往复,减少误检情况,从而提高检测的精度和检测效率。

2.4 损失函数改进

边界框回归 (bounding box regression, BBR) 的损失函数对于目标检测至关重要。它通过学习先验框到真值框的坐标映射关系, 输出位置调整量来修正预测框。损失函数 (loss function) 是用来衡量神经网络学习的预测输出与真实目标值之间差异的函数。它负责监督回归模型的训练, 通过惩罚预测框和真值框之间的误差, 驱动回归模型去逼近真值框的位置。良好的损失函数定义将为模型带来显著的性能提升, 合理设计的回归机制和损失函数是目标检测成功的关键。两者相互配合, 从而实现精确的检测。通常, 目标检测模型的损失函数包括类别置信度损失 L_{cls} (classification loss)、坐标回归损失 L_{loc} (localization loss) 以及目标置信度损失 L_{conf} (confidence loss), 如式 (1) 所示, 其中 λ 、 β 、 γ 为损失函数权重系数。

$$L = \lambda L_{cls} + \beta L_{loc} + \gamma L_{conf} \quad (1)$$

传统的损失函数在处理低质量的样本时会受到几何因素的惩罚, 从而降低模型的泛化性能。为了解决这个问题, 引入了一种新的损失函数 WIoU^[23] (wise intersection over union), 它通过引入距离机制来减轻几何因素的惩罚, 从而提高模型的泛化性能。因为训练数据中难以避免地包含低质量示例, 因此根据距离度量构建了距离注意力, 通过计算预测框和真实框中心点之间的距离来调整损失函数, 从而减轻距离因素的惩罚。将距离注意力机制的输出作为权重, 加权计算损失函数, 从而减小高质量的锚框的损失。

WIoU 损失函数的计算公式如式 (2) 所示, 其中 IoU 为交并比。作为目标定位的度量值, 用于评估模型定位的准确性。

$$\begin{cases} L_{IoU} = 1 - IoU, \\ R_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right), \\ L_{WIoU} = R_{WIoU} L_{IoU} \end{cases} \quad (2)$$

式中: x 和 y 为预测框的中心点坐标; x_{gt} 和 y_{gt} 为真实框的中心点坐标; W_g 和 H_g 为真实框的最小外接矩形的宽度和高度; $*$ 表示矩阵乘法。

3 实验与评估

3.1 评价指标选取

评价指标可以帮助评估模型在不同场景中的表现以及不同算法在同一任务上的优劣。通常, 目标检测的性能评估指标主要包括准确度 (accuracy)、召回率 (recall)、精确率 (precision)、AP (average

precision)、mAP (mean average precision)、FPS (frames per second) 等, 若将检测结果设定为正例 (positive) 和负例 (negative) 两种情况, 则最终存在的结果将包括以下 4 种: 即正确识别成正例的正例 TP (true positive)、错误识别成正例的负例 FP (false positive)、正确识别成负例的负例 TN (true negative) 以及错误识别成负例的正例 FN (false negative)。

Precision 是指在所有检测出的目标中检测正确的概率, 体现模型对负样本的区分能力。*Recall* 指所有真实的正样本中被检测出来的样本占有真正的正样本的比例, 体现模型对正样本的识别能力。*AP* 指的是检测出的框的平均准确率, 衡量模型在检测每一个类别的目标时的精确度。*mAP* 是多类别目标检测中的一种度量标准, 表示模型在多类别检测任务上的平均性能。它可以反映模型在不同类别的表现。*FPS*, 即单位时间内处理的图像帧数, 是衡量目标检测系统实时表现的重要指标之一。*FPS* 越高, 表示目标检测系统的处理帧率越快, 实时性越好。

3.2 数据集与实验环境设定

本研究中采用 EDS 数据集^[13], 其中包含了来自 3 台不同 X 光机器的 14 219 张图片, 共包括 10 类物品 (scissor, plastic bottle, power bank, lighter, umbrella, laptop, device, glass bottle, knife, pressure), 共计 31 655 个目标实例, 均由专业人员进行标注。本次实验中所使用的模型训练环境为 Ubuntu 20.04.2 操作系统, GPU 为 NVIDIA GeForce GTX 1080 Ti, 显存为 11 264 MB, CPU 为 Intel(R) Core(TM) i7-6850K, 频率 3.60 GHz, Python 版本为 3.7.13, 深度学习框架版本为 Torch 1.12.1+CUDA 10.2。训练参数方面, 初始学习率指训练开始时模型更新权重的速率, 设定为 0.01 有助于在初期稳定训练。动量用于加速收敛并有助于跳出局部最优解, 设置为 0.937 可以在梯度方向改变的情况下保持更新方向不变。权值衰减是一种正则化技术, 用于降低模型的复杂度, 减少过拟合风险。0.000 5 是调整后找到的一个合适的值。模型迭代次数和批量大小的选择通常基于训练数据集的大小和模型的复杂度。根据所使用的深度学习环境以及显存大小, 模型迭代次数和批量大小分别设置为 100 和 16。

3.3 性能分析

为了验证 LRCD 方法的有效性, 本文选择与 YOLO v4-tiny^[24]、YOLO v5s^[5] 这些近年来被广泛使用的轻量级检测模型进行对比, 实验在 EDS 数据集上进行, 结果如表 1 所示。可以看出 LRCD 在多个

指标上都取得了最好的检测效果。

表 1 不同模型在 EDS 数据集上的检测效果

Table1 Detection performance of different models on EDS dataset

指标	YOLO v4-tiny	YOLO v5s	LRCD
Precision/%	74.23	74.3	78.9
Recall/%	48.85	60.1	61.2
FPS	62.30	120.5	136.9
mAP/%	58.40	66.6	68.9

LRCD 的 *Precision* 为 78.9%，对比 YOLO v4-tiny 与 YOLO v5s 分别提升了 6.29%，6.19%。这证明改进提高了算法的精确度，使其检测出的目标中真正目标的比例增加，从而提高了精确率。LRCD 的 *Recall* 为 61.2%，对比 YOLO v4-tiny 与 YOLO v5s 分别约提升了 25.28%，1.83%。这说明了改进算法使检测器的召回能力增强，能检测出更多的真实目标，进而提高了召回率。LRCD 的 *FPS* 为 136.9，对比 YOLO v4-tiny 与 YOLO v5s 分别约提升了 119.7%，13.6%。这说明简化空间金字塔池化方法使得违禁品检测模型的计算效率得到了提升，检测效率与精度之间取得了更好的平衡。LRCD 的 *mAP* 为 68.9%，对比 YOLO v4-tiny 与 YOLO v5s 分别约提升了 17.98%，3.45%。这说明改进使得算法在提升 *Precision* 与 *Recall* 之外，还保障了多次检测中不同场景的稳定性，因此 *mAP* 得到了明显提升。

相较于 YOLO v4-tiny 与 YOLO v5s，LRCD 方法在 EDS 数据集中的单个对象实例检测中的绝大多数场景下都取得了最高的检测平均精度，不同模型在 EDS 数据集上的单个对象实例检测效果如表 2 所示。

表 2 不同模型在 EDS 数据集上的单个对象实例检测效果

Table 2 Individual object instance detection performance of different models on EDS dataset %

Class	YOLO v4-tiny	YOLO v5s	LRCD
device AP	56.31	67.8	71.8
glassbottle AP	51.31	69.5	77.4
knife AP	33.09	37.3	61.6
laptop AP	92.41	98.7	94.1
lighter AP	38.08	53.3	76.8
plasticbottle AP	64.11	59.3	73.0
powerbank AP	72.94	78.0	80.3
pressure AP	60.80	66.7	86.0
scissor AP	21.03	42.4	75.4
umbrella AP	93.38	93.5	92.9

LRCD 的实际检测效果如图 4 所示。从图中可以

观察到，模型可以准确地识别出待测对象，并对其位置和类别进行标注，给出检测置信度。




图 4 LRCD 在 EDS 数据集上的检测效果

Fig. 4 Detection performance of LRCD on the EDS dataset

3.4 消融实验结果分析

在 EDS 数据集上对 LRCD 进行消融实验，所得结果如表 3 所示。

表 3 LRCD 在 EDS 数据集上的消融实验结果

Table 3 Experimental results of LRCD ablation on EDS dataset %

Method	Precision	Recall	mAP
Baseline	74.3	60.1	66.6
+WIoU	74.8	60.6	67.1
+DenseOne	72.1	62.1	67.1
+Merge-NMS	73.2	62.1	67.0
+ SimSPPF	72.3	62.2	67.0

实验中的基准模型为 YOLO v5s，其 *Precision* 为 74.3%，*Recall* 为 60.1%，*mAP* 为 66.6%。引入 WIoU 作为损失函数后，其 *Precision* 提升了 0.5%，*Recall* 提升了 0.5%，*mAP* 提升了 0.5%。因此，可以认为改进损失函数能缓解正负样本不均衡，实现灵活的训练策略。通过使用基于跳跃连接思想的 DenseOne 模块，建立稠密连接，实现多尺度特征融合，改善信息流动，其 *Precision* 降低了 2.2%，*Recall* 提升了 2%，*mAP* 提升了 0.5%。使用 Merge-NMS 作为非极大值抑制方式后，其 *Precision* 降低了 1.1%，*Recall* 提升了 2%，*mAP* 提升了 0.4%，因此，可以认为该改进能够提高检测精度，降低漏检率，实现自适应的过滤策略。通过简化空间金字塔池化方法，模型的 *Precision* 降低了 2%，*Recall* 提升了 2.1%，*mAP* 提升了 0.4%。这是由于相比于普通的池化方法，简化的方法去掉了低分辨率的金字塔分支，只提取高分辨率特征，减少了

计算量, 但是同时降低了一部分精确率。

4 结语

本文针对 X 光下违禁品检测中的实时性问题, 围绕保持违禁品检测速度与精度的平衡开展研究, 提出一种面向交通安全的 X 光违禁品实时检测方法 LRCD, 该方法由高速违禁品检测网络 (HSCDNet) 和融合检测头 (FD-Head) 两个主要部分组成。在针对 X 光下行李物品的 EDS 数据集上的实验结果表明, LRCD 方法在精确率、召回率等重要指标上均实现了最高的检测性能, 其 *mAP* 达到了 68.9%。对比其他被广泛使用的先进模型平均提升达 6.35%, 基于 FPS 的检测效率同比增加了 66.7%。同时还保证了 EDS 数据集中绝大多数单项物品的平均检测精度, 为高效完成违禁品检测工作提供了保障。

参考文献:

- [1] ZHANG H T, NIU Y J, QIN H T, et al. Correlation and Binding Technology of Passenger Security Check Information Based on Video Target Detection and Tracking[C]//2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT). Dali: IEEE, 2022: 599–604.
- [2] 梁添汾, 张南峰, 张艳喜, 等. 违禁品 X 光图像检测技术应用研究进展综述[J]. Journal of Computer Engineering & Applications, 2021, 57(16): 74–82.
LIANG Tianfen, ZHANG Nanfeng, ZHANG Yanxi, et al. Summary of Research Progress on Application of Prohibited Item Detection in X-Ray Images[J]. Computer Engineering and Applications, 2021, 57(16): 74–82.
- [3] AKCAY S, BRECKON T. Towards Automatic Threat Detection: A Survey of Advances of Deep Learning Within X-Ray Security Imaging[J]. Pattern Recognition, 2022, 122: 108245.
- [4] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and Efficient Object Detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 10778–10787.
- [5] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: Improved YOLOv5 Based on Transformer Prediction Head for Object Detection on Drone-Captured Scenarios[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 2778–2788.
- [6] GE Z, LIU S, WANG F, et al. YoloX: Exceeding Yolo Series in 2021[J]. ArXiv Preprint ArXiv, 2021: 2107.08430.
- [7] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as Points [J]. ArXiv Preprint ArXiv, 2019: 1904.07850.
- [8] 张珂, 张良. 复杂背景下多尺度 X 光违禁品检测[J]. 激光与光电子学进展, 2021, 58(22): 2210002.
ZHANG Ke, ZHANG Liang. Multi-Scale Detection for X-Ray Prohibited Items in Complex Background[J]. Laser & Optoelectronics Progress, 2021, 58(22): 2210002.
- [9] 郭守向, 张良. Yolo-C: 基于单阶段网络的 X 光图像违禁品检测[J]. 激光与光电子学进展, 2021, 58(8): 0810003.
GUO Shouxiang, ZHANG Liang. Yolo-C: One-Stage Network for Prohibited Items Detection Within X-Ray Images[J]. Laser & Optoelectronics Progress, 2021, 58(8): 0810003.
- [10] RAFIEI M, RAITOHARJU J, IOSIFIDIS A. Computer Vision on X-Ray Data in Industrial Production and Security Applications: A Comprehensive Survey[J]. IEEE Access, 2023, 11: 2445–2477.
- [11] ZHU Y, ZHANG Y T, ZHANG H G, et al. Data Augmentation of X-Ray Images in Baggage Inspection Based on Generative Adversarial Networks[J]. IEEE Access, 2020, 8: 86536–86544.
- [12] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely Connected Convolutional Networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 2261–2269.
- [13] TAO R S, LI H N, WANG T B, et al. Exploring Endogenous Shift for Cross-Domain Detection: A Large-Scale Benchmark and Perturbation Suppression Network[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans: IEEE, 2022: 21157–21167.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet Classification with Deep Convolutional Neural Networks[J]. Communications of the ACM, 2017, 60(6): 84–90.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770–778.
- [16] LI C, LI L, GENG Y, et al. YOLOv6 V3.0: A Full-Scale Reloading[J]. ArXiv Preprint ArXiv, 2023: 2301.05586.
- [17] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[J]. 32nd International Conference on Machine Learning, ICML 2015, 2015, 1: 448–456.
- [18] VIOLA P, JONES M. Rapid Object Detection Using a Boosted Cascade of Simple Features[C]//Proceedings

- of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai: IEEE, 2001: 1.
- [19] 赵文清, 严 海, 邵绪强. 改进的非极大值抑制算法的目标检测 [J]. 中国图象图形学报, 2018, 23(11): 1676-1685.
- ZHAO Wenqing, YAN Hai, SHAO Xuqiang. Object Detection Based on Improved Non-Maximum Suppression Algorithm[J]. Journal of Image and Graphics, 2018, 23(11): 1676-1685.
- [20] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single Shot Multibox Detector[C]//2016 European Conference on Computer Vision. Amsterdam: Springer, 2016: 21-37.
- [21] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [22] REN J, CHEN X H, LIU J B, et al. Accurate Single Stage Detector Using Recurrent Rolling Convolution[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 752-760.
- [23] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: Bounding Box Regression Loss with Dynamic Focusing Mechanism[J]. ArXiv Preprint ArXiv, 2023: 2301.10051.
- [24] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal Speed and Accuracy of Object Detection[J]. ArXiv Preprint ArXiv, 2020: 2004.10934.
- (责任编辑: 申 剑)
-

(上接第 25 页)

- XU Feng, WEI Jianhua, WU Chao. Numerical Analysis of Influence of Pit Excavation on Pile Foundation[J]. Chinese Journal of Underground Space and Engineering, 2009, 5(S2): 1503-1506, 1517.
- [12] 刘 畅, 赵露伟, 李文杰, 等. 深基坑开挖条件下抗拔单桩承载力性状研究 [J]. 地下空间与工程学报, 2017, 13(4): 1106-1114.
- LIU Chang, ZHAO Luwei, LI Wenjie, et al. Research on Capacity Characteristics of Single Tension Pile Under Deep Foundation Pit Excavation[J]. Chinese Journal of Underground Space and Engineering, 2017, 13(4): 1106-1114.
- [13] 曾亚武, 刘继国, 蔡元奇. 深基坑开挖引起的土体变形模拟 [J]. 武汉大学学报 (工学版), 2006, 39(5): 53-56, 63.
- ZENG Yawu, LIU Jiguo, CAI Yuanqi. Simulation of Soil Deformation Due to Excavation of Deep Foundation Pit[J]. Engineering Journal of Wuhan University, 2006, 39(5): 53-56, 63.
- (责任编辑: 申 剑)