

DOI:10.19651/j.cnki.emt.2518992

改进 YOLOv8n 的轻量化车钥匙检测系统^{*}

陈聪明 李俊俊

(郑州大学电气与信息工程学院 郑州 450001)

摘要: 针对家庭复杂场景下车钥匙难以凭人眼快速识别与定位的问题,本研究设计了一种基于 E-YOLOv8n 模型的实时检测系统。该系统通过无线 USB 摄像头采集视频流,搭载 E-YOLOv8n 模型的计算终端进行实时目标检测,并通过音频报警模块反馈检测结果。其中,E-YOLOv8n 模型为核心部分,其改进如下:首先,优化网络结构,采用 DSCConv 重构骨干网络,精简 P5 输出,降低网络计算冗余;其次,设计 DSPPF 模块,提高多尺度特征融合能力并降低计算量;再次,在骨干网络末端嵌入 Coord 注意力机制模块,通过坐标注意力聚焦关键特征并抑制背景干扰;最后,采用轻量化检测头 LWD 模块,保持检测精度并提高模型计算效率。基于自建的车钥匙数据集,实验结果表明:E-YOLOv8n 模型与初始 YOLOv8n 模型相比,计算量、参数数量和模型大小分别降低了 53.8%、32.8%、52.4%,精确度提升 1.7%,提升性能的同时大幅轻量化,便于将其部署到家庭环境中计算资源受限的设备使用。

关键词: 车钥匙;YOLOv8;DSCConv;DSPPF 模块;Coord 注意力机制;LWD 模块

中图分类号: TP391.41; TN919.8 **文献标识码:** A **国家标准学科分类代码:** 510.1050; 510.5010

Optimized YOLOv8n-based lightweight car key detection system

Chen Congming Li Junjun

(School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In order to address the challenge of inefficient and difficult visual identification and localization of car keys in complex home environments, this paper designs a real-time detection system based on the E-YOLOv8n model. This system captures video streams through a wireless USB camera, performs real-time object detection using a computing terminal equipped with the E-YOLOv8n model, and feeds back the detection results via an audio alarm module. The E-YOLOv8n model is the core component of the system, incorporating several key improvements: first, the network structure is optimized by reconstructing the backbone network with DSCConv and streamlining the P5 output to reduce computational redundancy. Second, a DSPPF module is designed to enhance multi-scale feature fusion while reducing computational cost. Third, a Coord attention mechanism module is embedded at the end of the backbone network to focus on key features through coordinate attention and suppress background interference. Finally, a lightweight detection head, the LWD module, is adopted to maintain detection accuracy while improving computational efficiency. Based on a self-constructed car key dataset, experimental results demonstrate that compared to the original YOLOv8n model, the E-YOLOv8n model reduces computational load, parameter count, and model size by 53.8%, 32.8% and 52.4%, respectively, while improving precision by 1.7%. These enhancements achieve significant lightweighting while boosting performance, making it more suitable for deployment on resource-constrained devices commonly found in home environments.

Keywords: car key; YOLOv8; DSCConv; DSPPF module; Coord attention mechanism; LWD module

0 引言

车钥匙是人们生活中常见的物品。传统燃油车的车钥匙上面一般都会预留钥匙孔以便穿在钥匙扣上使用,这样

即使钥匙丢了,相对来讲,也比较容易找到。但是,例如极氪、理想、蔚来等新能源汽车所配备的车钥匙上没有孔,而是一个整体,无法像燃油车钥匙那样串在钥匙扣上使用,这样单独使用的方式,大大增加了钥匙丢失的概率。况且家

收稿日期:2025-06-02

^{*} 基金项目:国家自然科学基金青年基金(62203396)项目资助

里环境复杂,比如家用物品的遮挡,光照的变化,背景的干扰等因素,用肉眼寻找起来往往难度很大。因此,设计一种检测精度高、检测速度快、轻量化便于家用部署的系统至关重要。

目标检测算法^[1]分为传统目标检测方法^[2]和基于深度学习的目标检测方法^[3]。传统目标检测方法受限于其核心设计原理,在性能与适应性上存在明显缺陷。随着科学技术的发展,基于深度学习的目标检测算法能够自动的学习到图像中的特征信息,大大提高了检测的精确度和效率。其可以分为两类:一类是两阶段检测算法,其首先生成潜在的候选目标区域,然后对每个候选区域进行分类和位置回归,代表性算法有 R-CNN^[4] (region-based convolutional neural network) 系列;一类是单阶段检测算法,其核心思想是直接通过神经网络预测目标的类别和位置,无需候选区域生成阶段,把检测任务变为回归问题,代表性算法有 SSD^[5] (single shot multibox detector)、YOLO^[6] (you Only look once) 系列等。

自 YOLO 算法面世以来,受到众多学者的广泛关注。相较于其他算法,YOLO^[7] 系列算法兼顾检测速度与精度,更适用于对目标的实时检测任务。Mu^[8] 将 YOLOv2 网络应用于输电线路设备图像识别,通过端到端的回归方法实现了 90.9% 的识别精度和 30 FPS(frames per second) 的实时检测速度,有效平衡了复杂背景下多类设备识别的准确性与效率,但是对密集小目标的检测能力不足。He 等^[9] 提出了一种基于改进 YOLOv3 模型的垃圾收运监管系统,通过深度可分离卷积和三元注意力机制的双重优化,实现了 98.5% 的 mAP(mean average precision) 和 68.5 FPS 的检测速度,有效解决了传统方法在复杂环境下对小目标检测精度不足的问题,但是针对极端遮挡等仍有不足。Ma 等^[10] 通过多阶段模型压缩技术(稀疏训练、剪枝、知识蒸馏和量化)显著降低了 YOLOv4 的计算复杂度和内存占用,在保持高检测精度同时,模型大小减少 98.63%,推理速度提升 4.2 倍,并成功部署在低功耗边缘设备,但其训练效率低且针对小目标检测仍有不足。Zhong 等^[11] 通过引入轻量化卷积模块、全局-局部特征融合模块和多尺度注意力动态检测头,提升了 YOLOv5 算法针对道路缺陷的检测精度,并降低了 4.4% 计算量,但是未在更多数据集上验证泛化能力。Yang 等^[12] 提出一种改进 YOLOv6 的湿地鸟类检测方法,通过引入 SENet(squeeze-and-excitation network) 注意力机制和迁移学习,在丹顶鹤数据集上实现 98.4% 检测精度,但未验证其他鸟类的泛化性。Hu 等^[13] 通过多样化分支块+部分卷积模块、轻量化特征融合模块、归一化 Wasserstein 距离度量改进 YOLOv7,提高了对烟雾火灾的检测精度同时降低了计算量,但未验证极端场景。Liu 等^[14] 针对实时车辆检测问题,提出了一种改进的 YOLOv8 模型,通过特征共享与动态交互检测头、多尺度特征增强和上采样优化,在减少 27% 参数量的同时略微提升精度,但

在极端场景适应性和推理速度优化方面仍有改进空间。李忠科等^[15] 提出了一种基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法,通过调整网络结构、设计 C2f-GhostD (cross-stage partial ghost dilated) 和 POne-Detect (parallel one-step detection head) 模块、引入 SimAM (simple attention mechanism) 注意力机制,在保持高精度的同时显著降低参数量和模型体积,但实验仅针对单一 PCB 数据集验证,未涉及复杂工业场景的泛化性测试,且未实际部署到硬件设备验证实时性。易磊等^[16] 通过引入基于星型操作的轻量级网络,跨层自适应融合注意力机制、动态检测头、优化损失函数,在降低计算量 8.02% 的同时将 mAP 提升至 95.2%,显著提升输电线路异物检测的精度与效率,但实验未验证模型在极端天气下的鲁棒性,且动态检测头与轻量化模块的联合优化可能引入特征损失,需进一步平衡精度与轻量化。

YOLOv8 系列作为 Ultralytics 团队在 2023 年发布的版本,其具备较高的精度和速度,适用于对检测车钥匙任务的针对性优化。即使 YOLOv8n 已经是 YOLOv8 系列参数量计算量最小的版本,但是面对计算资源受限的设备仍难以部署。因此,本研究基于 YOLOv8n 为框架进行优化,目的是轻量化模型的同时增加检测精度,提出了一种车钥匙检测模型(efficient-you only look once version 8 nano, E-YOLOv8n),并结合相关硬件予以实际化应用,本研究的主要贡献如下:

- 1) 优化网络结构,采用深度可分离卷积(depthwise separable convolution, DSConv) 重构骨干网络,精简 P5 输出,降低网络计算冗余。

- 2) 设计深度快速空间金字塔池化模块(deep spatial pyramid pooling fast, DSPPF),提高多尺度特征融合能力并降低计算量。

- 3) 在骨干网络末端嵌入 Coord 注意力机制模块,通过坐标注意力聚焦关键特征并抑制背景干扰。

- 4) 采用轻量化检测头模块(light weight detect, LWD),保持检测精度并提高模型计算效率。

1 YOLOv8n 网络介绍

YOLO 是一种单阶段目标检测算法,其核心思想是将目标检测任务转化为端到端的回归问题,直接在图像中预测物体的边界框和类别概率。与传统检测算法相比,其兼顾速度与精度、实时性强,得到广泛应用。YOLOv8 系列是 Ultralytics 团队在 2023 年发布的版本,其具备较高的精度和速度。按照参数量大小分为 5 个版本,从小到大依次为: YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x。结合实际场景,本研究选用最小的 YOLOv8n 模型予以改进。YOLOv8 分为三大部分:骨干网络(Backbone)、颈部网络(Neck)、检测头(Head),如图 1 所示。

骨干网络(Backbone)用于高精度特征提取,其包括第

信息,调整输出通道数,无空间维度计算。相较于标准卷积,该操作不但可以大幅减少计算量和参数量,同时也能保持较好的特征提取能力,其结构如图 3 所示,参数量和计算量如式(4)、(5)所示。

$$\text{DSCConv}_{\text{参数量}} = D_K^2 \times M + M \times N \quad (4)$$

$$\text{DSCConv}_{\text{计算量}} = D_K^2 \times M \times D_{FF}^2 + M \times N \times D_{FF}^2 \quad (5)$$

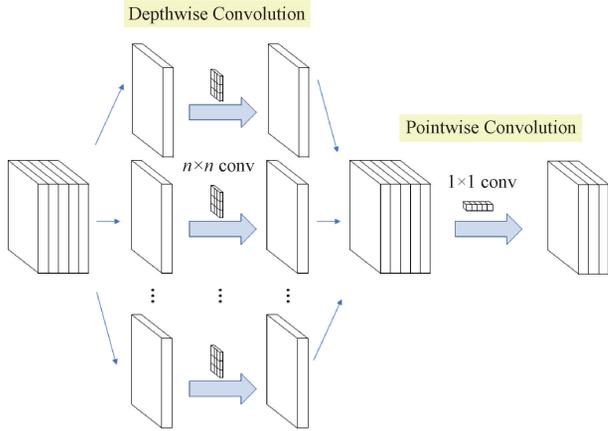


图 3 DSCConv 结构

Fig. 3 DSCConv structural

YOLOv8n 骨干网络包括 10 层,其中 Conv 层有 5 个,分别为第 0、1、3、5、7 层,其对应的特征图分别为 P1、P2、P3、P4、P5。每层的卷积核大小均为 \$3 \times 3\$,步长均为 2,重复次数均为 1,均接收来自上一层的信息,代入参数量计算量的公式可得 Conv 计算量参数量为 DSCConv 的 \$\frac{9N}{9+N}\$ 倍,又由于输出通道数 \$N\$ 远大于 9(层数越高输出通道越大越明显),得到 Conv 的计算量参数量约为 DSCConv 的 9 倍,故 DSCConv 可以大幅降低计算量参数量。

2.2 DSPPF 模块

YOLOv8n 算法中的 SPPF 模块,首先通过一个标准卷积模块降维输入;然后经过 3 次最大池化^[20]操作等效不同的感受野,其中的 \$K=5\$,其等效于 \$5 \times 5, 9 \times 9, 13 \times 13\$ 的 3 次池化操作;最后再将经过 3 次最大池化的多尺度特征进行拼接操作,通过一个标准卷积模块升维输出。最大池化通过选取滑动窗口内的最大值作为输出,能够有效保留局部显著的特征,如边缘、纹理等;还可以增强模型对微小平移的鲁棒性且同时抑制噪声;但是其仅保留局部极值忽略整体分布信息,可能弱化全局上下文信息;若窗口内存在多个噪声点,最大池化可能会放大噪声对其的影响。平均池化^[21]则通过取窗口内平均值平滑特征作为输出,其保留了整体分布的信息,适合全局特征的提取;噪声被平均化可以增强对噪声的鲁棒性,平滑操作可减少模型对局部噪声的过拟合风险;但是其会削弱局部的细节特征,并且对目标位置的偏移较为敏感。最大池化和平均池化各有各的优点,混合池化融合了最大池化和平均池化的优点,兼顾局部细节与全局分布,在同样的场景下可以表现出更强的鲁

棒性。

改进后的混合池化通过加权融合(0.7 最大池化+0.3 平均池化),不但强化了关键特征的提取能力,而且保留了整体上下文信息,这种设计在复杂场景(如背景干扰,遮挡等)表现更佳。最大池化负责捕捉局部强响应特征,平均池化负责抑制噪声并增强纹理连贯性,加权融合平衡了两者的优势,避免了单一池化对噪声和稀疏特征的敏感性。使用深度可分离卷积 DSCConv 代替 SPPF 模块中的第一个标准卷积 Conv, DSCConv 通过逐通道卷积,强化每个通道的局部特征提取能力,避免普通 \$1 \times 1\$ 卷积可能导致的特征冗余。这一操作不但可以大幅降低卷积带来的计算量,而且为后续的通道压缩策略进一步压缩第 2 个卷积的计算成本,其在保持特征表达能力同时还优化了推理速度,兼顾了精度与速度。3 次加权混合池化生成的特征图包含不同尺度的上下文信息,第 1 次加权混合池化保留原始输入的细节,第 2 次加权混合池化扩大感受野至 \$9 \times 9\$,第 3 次加权混合池化扩大感受野至 \$13 \times 13\$,最终拼接后的特征维度更高,有助于模型学习多尺度的特征,特征金字塔的表征能力更强。通过加权混合池化与深度可分离卷积,实现了模型的多尺度特征增强、计算成本降低与鲁棒性的提升,其结构如图 4 所示。

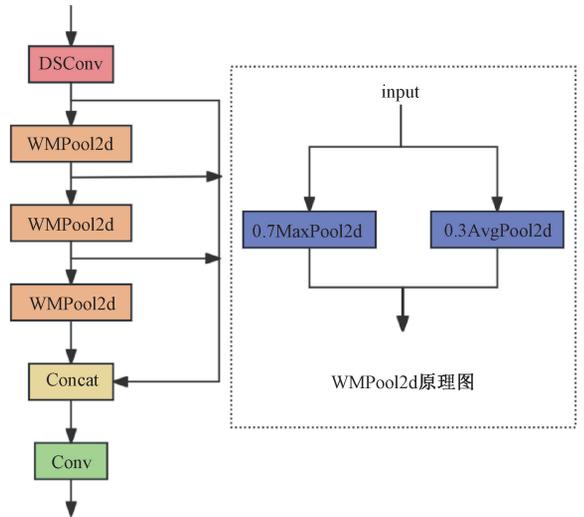


图 4 DSPPF 模块结构

Fig. 4 DSPPF module structure

2.3 Coord 注意力机制

Coord^[22]注意力机制通过显式编码坐标信息,将传统通道注意力的全局池化解耦为水平与垂直方向的 1D 特征编码,增强了模型对边缘纹理等特征的敏感程度(如车钥匙的弧形倒角等),这有利于对小目标的检测;同时还可以抑制无关区域的响应,减少误检的发生。在 YOLOv8 的主干网络中,经过第 0、1、3、5、7 层的 Conv 模块分别生成了 P1、P2、P3、P4、P5 特征图,经过第 2、4、6、8 层的 C2f 模块和第 9 层的 SPPF 模块,在骨干网络的末端(第 9 层后)汇聚了丰

富的多尺度特征,将Coord注意力机制应用于骨干网络末端作为第10层可以更有效地捕捉和利用全局与局部的空间结构信息,提高目标检测的准确度。

Coord注意力机制是一种高效轻量化的注意力机制,由Hou等^[22]于2021年提出。其致力于解决传统注意力机制(如SE(squeeze-and-excitation network)、CBAM(convolutional block attention module)等)对空间位置信息利用不足的问题,增强模型对目标位置和尺度的感知能力。具体而言,其分为两大步骤:坐标信息嵌入和坐标注意力生成。其首先过两条并行的分支路径分别捕获水平方向和垂直方向的位置特征,水平方向池化对每个通道 C 和高度 H ,沿宽度方向取平均,如式(6)所示。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} x_c(h, i) \quad (6)$$

垂直方向池化对每个通道 C 和宽度 W ,沿高度方向取平均,如式(7)所示。

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} x_c(j, w) \quad (7)$$

拼接水平与垂直特征,通过共享的 1×1 卷积和非线性激活函数,如式(8)所示。

$$f = \delta(F_1([z^h, z^w])) \quad (8)$$

将 f 沿空间维度分割为 f^h 和 f^w ,再通过 1×1 卷积和sigmoid生成注意力图,如式(9)、(10)所示。

$$g^h = \sigma(F_h(f^h)) \quad (9)$$

$$g^w = \sigma(F_w(f^w)) \quad (10)$$

输入特征 x 分别与 g^h 和 g^w 逐元素相乘增强目标区域,如式(11)所示。

$$y_c(i, j) = x_c(i, j) \times g^h(i, j) \times g^w(j) \quad (11)$$

具体而言,Coord注意力机制是一种创新的轻量级注意力机制,通过将位置信息显式嵌入通道注意力中,显著提升了模型对空间结构的感知能力。将全局池化解耦为水平(宽度)和垂直(高度)的1D池化,分别保留坐标信息;拼接双向特征后生成空间-通道注意力图,通过乘法增强目标区域;相较于SE^[23]仅依赖通道注意力的局限性,以及CBAM^[24]需要额外卷积层引入位置信息的冗余设计,Coord注意力通过坐标方向的先验约束实现了更高效的表征学习,其结构如图5所示。

2.4 LWD检测头模块

YOLOv8的检测头部分,负责接收来自第15、18、21大层的输出,对应的分别是特征金字塔P3、P4、P5特征图的最终输出。以输入分辨率 640×640 为例,P3输出为 80×80 ,负责检测小目标;P4输出为 40×40 ,负责检测中等目标;P5输出为 20×20 ,负责检测大目标。首先输入的特征图,上路经过2个串联的 3×3 卷积,再经过1个 1×1 卷积,最后得到边界框回归损失^[25];下路经过2个串联的 3×3 卷积,再经过1个 1×1 卷积,最后得到分类损失^[26]。其中连续的2个 3×3 标准卷积,第1个的作用为降维和初步

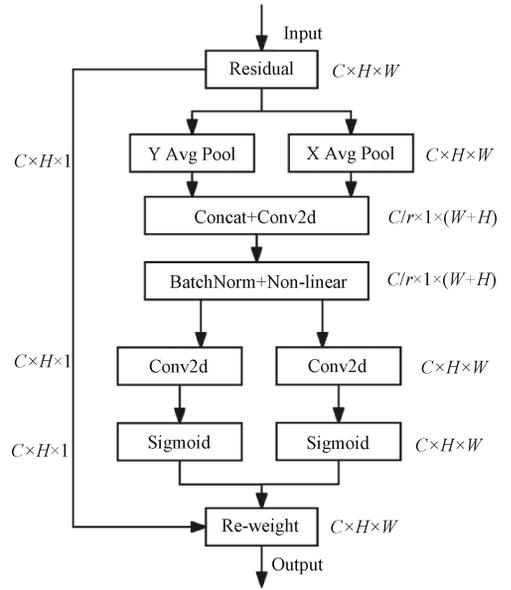


图5 Coord注意力机制原理图

Fig. 5 Schematic diagram of the Coord attention mechanism

的特征提取,第2个的作用为深度特征提取,面对复杂的目标,这样的操作在计算成本和特征表达能力之间取得了平衡。

但是,面对车钥匙检测这一具体任务而言,由于其特征并不复杂,使用2个串联的 3×3 标准卷积会造成大量的计算冗余,降低计算效率。故引入DSCConv重构上路第1个标准卷积和下路的第1个标准卷积,上下两路的第2个标准卷积不变,这一操作不但可以提高计算效率,而且还能保持较高的精度,其结构如图6所示。

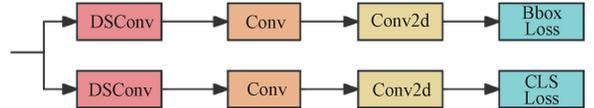


图6 LWD模块结构

Fig. 6 LWD module structure

3 实验设计与结果分析

3.1 实验环境与参数配置

实验所用系统为Win10, GPU为RTX 4060Ti(8 GB), CPU为i5 14600kf, 内存为32 GB, 编程语言为Python3.8.2, 深度学习框架为PyTorch 2.4.1 + CUDA 11.8。训练参数设置如表1所示。

3.2 数据集

本实验所用数据集为自制车钥匙数据集,其是基于极氪汽车车钥匙在多个家用场景下采集而来,包含一个类ZEEKR,共计600张图片。训练集、验证集、测试集分别按照8:1:1的比例分配。其中包括车钥匙与多种不同家用物品的排列组合,包含简单背景、背景杂乱、不同程度遮挡、小目标等场景。

表 1 训练参数设置

Table 1 Training parameter settings

参数	设置
batch	16
workers	8
epochs	100
imgsz	640
cache	ram

3.3 评价指标

本实验使用精确度 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision @ 0.5, $mAP@0.5$)、参数量 Parameters、计算量 GFLOPS (每秒千兆次浮点运算), 模型大小 Model size 为评价模型性能的指标。

精确度 P 衡量模型预测正样本的准确性, 如式 (12) 所示。

$$P = \frac{TP}{TP + FP} \quad (12)$$

召回率 R 衡量模型捕获正样本的能力, 如式 (13) 所示。

$$R = \frac{TP}{TP + FN} \quad (13)$$

平均精度均值 mAP 是所有类别 AP 的平均值, 如式 (14) 所示。

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (14)$$

IoU 是预测框与真实框的交并比, 如式 (15) 所示。

$$IoU = \frac{\text{预测框} \cap \text{真实框}}{\text{预测框} \cup \text{真实框}} \quad (15)$$

其中, TP 是正确预测的正样本数, FP 是错误预测的正样本数, FN 是漏检的正样本数, N 为类别数, AP 是对 PR 曲线进行插值计算曲线下的面积。

3.4 对比试验

为了验证本研究算法 E-YOLOv8n 相较于常规汽车钥匙检测模型的优越性, 以精确度 P 、召回率 R 、平均精度均值 $mAP@0.5$ 、参数量 Parameters、计算量 GFLOPS (每秒千兆次浮点运算), 模型大小 Model size 为评价指标, 将本研究算法与 YOLOv3、YOLOv5、YOLOv8、YOLOv10、YOLOv11 算法在相同的条件下进行对比实验 (配置与数据集等均完全相同)。

根据表 2 可得, 本研究改进后的 E-YOLOv8n 模型与其他模型相比, $mAP@0.5$ 是最高的, 精确度仅比 YOLOv11 略低, 召回率是最高的, 参数量是最小的, 计算量是最小的, 模型大小是最低的, 本研究改进后的模型充分展示了其优越性。

3.5 消融实验

为了验证本研究改进的有效性, 以原有模型 YOLOv8n 为基础, 并以精确度 P 、召回率 R 、平均精度均值 $mAP@0.5$ 、参数量 Parameters、计算量 GFLOPS (每秒千兆次浮点运算), 模型大小 Model size 为评价指标, 通过多个改进的组合进行消融实验, 如表 3 所示。

表 2 不同算法对比实验

Table 2 Comparative experiments of different algorithms

算法	$mAP@0.5/\%$	$P/\%$	$R/\%$	Parameters/ 10^6	GFLOPS	Model size/MB
YOLOv3-tiny	98.56	98.30	96.63	12.13	19.04	23.24
YOLOv5n	99.50	99.89	100	2.51	7.18	5.02
YOLOv8n	99.48	98.26	100	3.01	8.19	5.95
YOLOv10n	97.08	95.90	91.67	2.71	8.39	5.48
YOLO11n	99.50	99.91	100	2.59	6.44	5.21
ours	99.50	99.89	100	1.39	5.50	2.83

表 3 消融实验

Table 3 Ablation experiment

DSCConv	DSPPF	LWD	CoordAtt	$mAP@0.5/\%$	$P/\%$	$R/\%$	Parameters/ 10^6	GFLOPS	Model size/MB
×	×	×	×	99.48	98.26	100	3.01	8.19	5.95
√	×	×	×	99.50	98.31	100	1.63	6.91	3.29
×	√	×	×	99.50	99.82	100	2.98	8.17	5.89
×	×	√	×	99.50	98.80	100	2.50	6.57	4.98
×	×	×	√	99.50	99.52	100	3.02	8.20	5.97
√	√	×	×	99.50	99.98	100	1.60	6.89	3.23
√	√	√	×	99.45	98.36	99.98	1.38	5.50	2.82
√	√	√	√	99.50	99.89	100	1.39	5.50	2.83

据表 3 可得, 优化网络结构大幅降低了计算量参数量

且不降低精度和召回率; DSPPF 模块的引入提高了精度,

同时也降低了参数量计算量;LWD模块的引入在不影响精度的前提下大幅降低了参数量计算量;Coord注意力机制的引入,虽然稍微增加了少许的计算量参数量,但是可以弥补前3个轻量化措施同时存在时带来的精度召回率下降的问题。通过表2的实验结果可得,改进后的模型与初始YOLOv8n模型相比,计算量、参数量和模型大小分别降低了53.8%、32.8%、52.4%,有效的降低了模型部署于算力较弱设备的难度与成本,在满足实时性的同时又提升了精度,证实了本研究改进的有效性。

3.6 算法验证

实例化家用场景予以验证,图7(a)是YOLOv8n模型的检测结果,图7(b)是E-YOLOv8n的检测结果。第1张图(目标距离较远)初始算法正确检测,改进算法精度更高;第2张图(存在反光有干扰)初始算法误检,改进算法没有失误;第3张图(环境杂乱)初始算法误检,改进算法精确检测;第4张图(目标被部分遮挡)初始算法正确检测,改进算法检测精度更高。由此可得,改进算法在大幅轻量化的同时,检测精度有效提高,漏检误检有效降低,对背景杂乱、存在干扰、遮挡、小目标等场景有良好的性能,证实了所提出E-YOLOv8n模型的实际价值。

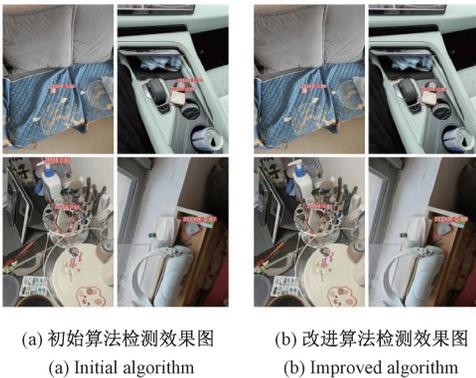


图7 检测结果对比图

Fig.7 Comparison chart of test result

4 结 论

在复杂家庭环境中丢失车钥匙后,为了快速对其识别与定位,本研究提出了一种高效、轻量化的E-YOLOv8n模型对车钥匙进行检测,并结合USB无线摄像头、计算机和音频报警模块予以实例化应用。首先,优化网络结构,采用DSCov重构骨干网络,精简P5输出,降低网络计算冗余;其次,设计深度混合池化空间金字塔模块DSPPF,提高多尺度特征融合能力并降低计算量;再次,在骨干网络末端嵌入Coord注意力机制,聚焦关键特征并抑制背景干扰;最后,采用轻量化检测头LWD模块,保持检测精度并提高模型计算效率。基于自建的车钥匙数据集(车钥匙特指极氪汽车车钥匙),实验结果表明:改进后的模型与初始YOLOv8n模型相比,计算量、参数量和模型大小分别降低

了53.8%、32.8%、52.4%,精确度提升1.7%。

综合来看,改进后的E-YOLOv8n模型不但有较高的精确度,而且在YOLOv8n模型的基础上大幅轻量化,便于在家用计算机上部署。未来将继续改进,使该模型在具有更高精度的基础上更加轻量化,便于在边缘计算等计算资源更为受限的平台部署。

参考文献

- [1] 方路平,何杭江,周国民. 目标检测算法研究综述[J]. 计算机工程与应用, 2018, 54(13): 11-18.
FANG L P, HE H J, ZHOU G M. Survey of object detection algorithms[J]. Computer Engineering and Applications, 2018, 54(13): 11-18.
- [2] 郭虎升. 目标检测综述:从传统方法到深度学习[J]. 新兴科学与技术趋势, 2024, 3(2): 128-145.
GUO H SH. Object detection review: From traditional methods to deep learning[J]. Emerging Science and Technology Trends, 2024, 3(2): 128-145.
- [3] 许德刚,王露,李凡. 深度学习的典型目标检测算法研究综述[J]. 计算机工程与应用, 2021, 57(8): 10-25.
XU D G, WANG L, LI F. Survey of typical object detection algorithms in deep learning[J]. Computer Engineering and Applications, 2021, 57(8): 10-25.
- [4] LIU X, WANG H, JING H, et al. Research on intelligent identification of rock types based on faster R-CNN method [J]. IEEE Access, 2020, 8: 21804-21812.
- [5] CHEN Z, WU K, LI Y, et al. SSD-MSN: An improved multi-scale object detection network based on SSD[J]. IEEE Access, 2019, 7: 80622-80632.
- [6] ZHANG J, XU C, SHEN S, et al. MFF-YOLO: An improved YOLO algorithm based on multi-scale semantic feature fusion [J]. Tsinghua Science and Technology, 2025, 30(5): 2097-2113.
- [7] HUSSAIN M. YOLOv1 to v8: Unveiling each variant-a comprehensive review of YOLO[J]. IEEE Access, 2024, 12: 42816-42833.
- [8] MU Z Q. Transmission line inspection image recognition technology based on YOLOv2 network [C]. 2018 International Conference on Security, Pattern Analysis, and Cybernetics(SPAC). Jinan: IEEE, 2018: 421-428.
- [9] HE Y, LI J, CHEN S, et al. Waste collection and transportation supervision based on improved YOLOv3 model [J]. IEEE Access, 2022, 10: 81836-81845.
- [10] MA X, JI K, XIONG B, et al. Light-YOLOv4: An edge-device oriented target detection method for remote sensing images[J]. IEEE Journal of Selected

- Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 10808-10820.
- [11] ZHONG S, CHEN C, LUO W, et al. DDVC-YOLOv5: An improved YOLOv5 model for road defect detection [J]. IEEE Access, 2024, 12: 134008-134019.
- [12] YANG X, ZHOU C, YU J, et al. A new strategy for bird detection in coastal wetlands based on improved YOLOv6 3.0[C]. 2023 2nd International Conference on Artificial Intelligence and Intelligent Information Processing(AIIP). Hangzhou: IEEE, 2023: 293-296.
- [13] HU J, HE Y, ZENG M, et al. Smoke and fire detection based on YOLOv7 with convolutional structure reparameterization and lightweighting [J]. IEEE Sensors Letters, 2024, 8(8): 6009604.
- [14] LIU X, WANG Y, YU D, et al. YOLOv8-FDD: A real-time vehicle detection method based on improved YOLOv8[J]. IEEE Access, 2024, 12: 136280-136296.
- [15] 李忠科, 刘小芳. 基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法[J]. 电子测量技术, 2024, 47(4): 120-126.
- LI ZH K, LIU X F. PCB defect detection algorithm based on lightweight YOLOv8n network [J]. Electronic Measurement Technology, 2024, 47(4): 120-126.
- [16] 易磊, 黄哲玮, 易雅雯. 改进 YOLOv8 的输电线路异物检测方法[J]. 电子测量技术, 2024, 47(15): 125-134.
- YI L, HUANG ZH W, YI Y W. Foreign object detection method for transmission lines based on improved YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(15): 125-134.
- [17] ZHANG Z T, ZHANG X, SHAO Z. Deform-FPN: A novel FPN with deformable convolution for multi-scale SAR ship detection[C]. IGARSS 2023—2023 IEEE International Geoscience and Remote Sensing Symposium, Pasadena: IEEE, 2023: 5273-5276.
- [18] AADARSH Y G, SINGH G. Comparing UNet, UNet++, FPN, PAN and Deeplabv3+ for gastrointestinal tract disease detection[C]. 2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques (EASCT). Bengaluru: IEEE, 2023: 1-7.
- [19] NASCIMENTO M G D, PRISACARIU V, FAWCETT R. DSConv: Efficient convolution operator [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 5147-5156.
- [20] MORE Y, DUMBRE K, SHIRAGAPUR B. Horizontal max pooling a novel approach for noise reduction in max pooling for better feature detect[C]. 2023 International Conference on Emerging Smart Computing and Informatics(ESCI). Pune: IEEE, 2023: 1-5.
- [21] JIANG P, ZOU C. Convolution neural network with multiple pooling strategies for speech emotion recognition[C]. 2022 6th International Symposium on Computer Science and Intelligent Control (ISCSIC). Beijing: IEEE, 2022: 89-92.
- [22] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 13708-13717.
- [23] ZHU H Y, WANG L SH, SHEN N, et al. MS-HNN: Multi-scale hierarchical neural network with squeeze and excitation block for neonatal sleep staging using a single-channel EEG[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 2195-2204.
- [24] YANG C, WU Z. Speech enhancement method based on generative adversarial network and convolutional block attention module [C]. 2024 6th International Conference on Communications, Information System and Computer Engineering (CISCE). Guangzhou: IEEE, 2024: 682-686.
- [25] GAO F, ZHONG F, SUN J, et al. BBox-free SAR ship instance segmentation method based on Gaussian heatmap[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5206218.
- [26] SABARINATH G, MANOHAR T G. Optimal sitting and sizing of renewable energy resources for power loss reduction in radial distribution systems using whale optimization algorithm [C]. 2018 International Conference on Emerging Trends and Innovations in Engineering and Technological Research (ICETIETR). Ernakulam: IEEE, 2018: 1-5.

作者简介

陈聪明, 硕士研究生, 主要研究方向为目标检测、运动控制。

E-mail: 215788093@qq.com

李俊俊(通信作者), 博士, 讲师, 主要研究方向为人机交互、技能传递学习、机器人运动控制与规划。

E-mail: muziljj@zzu.edu.cn