

文章编号: 2095-2163(2024)01-0022-07

中图分类号: TP391.4

文献标志码: A

改进 YOLOv5s 的室内喷涂机器人的窗户检测算法

李晓宇^{1,2}, 张功学¹, 何凯², 黄波²

(1 陕西科技大学 机电工程学院, 西安 710021; 2 中国科学院深圳先进技术研究院, 深圳 518055)

摘要: 室内窗户检测对喷涂机器人实现自动化喷涂作业有着重要意义。现有的窗户检测模型受光照环境影响较大,且无法识别局部窗户图像,参数量多、计算量大,难以部署在算力有限的喷涂机器人上。针对以上问题,本文提出一种改进 YOLOv5s 网络的轻量级室内窗户检测算法,在 YOLOv5s 网络的基础上引入 PP-LCNet 和 GhostNetv2 两个轻量级网络,降低模型的参数量和计算量,提升模型的实时检测速度;再将基于 Transformer 编码的 C3TR 模块添加到主干网络,增强模型的特征提取能力,并使用 SIoU 损失函数加快网络的收敛速度,保留有利特征。实验结果表明,本文改进的算法相较于原算法参数量降低了 77.7%,权重文件减小了 75.7%,检测速度提高了 77.8%,平均精度均值提升了 2.9%。

关键词: 喷涂机器人; 室内窗户检测; YOLOv5s; 轻量级网络; 损失函数

Improved YOLOv5s's window detection algorithm of indoor spraying robot

LI Xiaoyu^{1,2}, ZHANG Gongxue¹, HE Kai², HUANG Bo²

(1 College of Mechanical and Electrical Engineering, Shaanxi University of Science & Technology, Xi'an 710021, China;

2 Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

Abstract: An indoor window detection is very important for spraying robot to realize automatic spraying operation. The existing window detection model is greatly affected by the illumination environment and cannot identify the local window image, which has a large number of parameters and a large amount of calculation, so it is not suitable for deployment on the spraying robot with limited computational power. To solve the above problems, this paper proposes a lightweight indoor window detection algorithm based on improved YOLOv5s network. Based on YOLOv5s network, PP-LCNet and GhostNetv2 networks are introduced in this algorithm to reduce the number of parameters and computation and improve the real-time detection speed of the model. Then the C3TR module based on Transformer encoding is added to the Backbone network to enhance the feature extraction ability of the model. The SIoU loss function is used to accelerate the convergence of the network and retain favorable features. The experimental results show that the improved algorithm reduces the number of parameters by 77.7% and the weight file by 75.7%, improves the detection speed by 77.8%, and the average accuracy rate is increased by 2.9%.

Key words: spraying robot; indoor window detection; YOLOv5s; lightweight network; loss function

0 引言

目前,室内喷涂工作主要还是依靠人工作业。随着中国老龄化问题加重,劳动力成本升高,使用喷涂机器人代替人工作业成为建筑业发展的重中之重。虽然现有的室内喷涂机器人基本实现了墙面喷涂功能,但自动化程度不高,原因在于机器人缺乏对环境中不可喷涂区域的识别,要想使机器人做到自主喷涂,需要对窗户这种无需喷涂的区域进行检测。

由于玻璃具有透光属性,会导致算法的准确性容易受到光线强弱的影响,且窗户外面的复杂环境也会对检测结果造成干扰。此外,还存在喷涂机器人工作时距离墙面较近,拍摄到的大多是局部窗户图像的问题,给室内窗户检测带来了一定的困难。

近年来,在窗户识别检测方面已有许多使用传统目标检测算法进行的研究。孔倩倩等^[1]基于窗户图像的轮廓分析,采用边界追踪算法提取轮廓坐标点,用最小生成树对矩形分类合并来确定窗户位

基金项目: 中国博士后科学基金(2022M713280); 深圳市优秀科技创新人才培养项目(RCBS20221008093056024)。

作者简介: 李晓宇(1996-),男,硕士研究生,主要研究方向:装修机器人、图像处理; 张功学(1964-),男,博士,教授,主要研究方向:机械 Engineering 动力学; 何凯(1972-),男,博士,高级工程师,主要研究方向:机电系统自动化、精密制造及工业机器人。

通讯作者: 黄波(1991-),男,博士,助理研究员,主要研究方向:数控技术与装备、工业机器人。Email: bo.huang@siat.ac.cn

收稿日期: 2023-10-10

置;Neuhausen 等^[2]将一个由阈值 Haar 样特征组成的软级联分类器和一个提取图像进行分类的滑动窗口检测器结合,提高了窗户检测率,同时减少了所需特征的数量;高云龙等^[3]利用模板匹配选取单个窗户作为样本,对 JointBoost 分类器进行训练,建立窗户分布模型,最终得到提取后的窗户。以上方法虽然在窗户检测上具有一定效果,但是这些传统检测算法需要人工提取窗户特征,设计过程较为复杂,检测精度和识别速度较低,不适合应用在喷涂机器人上。

随着计算机视觉的不断发展,许多研究者将深度学习技术应用于目标检测,提出了更高效的窗户检测算法。Ma 等^[4]提出了一种用于窗户检测的改进 Faster R-CNN (Fast Region-based Convolutional Network) 算法,使用 RoI (Region of Interest) 特征融合和上下文增强模块,提升了检测精度,但模型复杂、计算量大;张祖宇等^[5]使用 Mask-RCNNs 算法,通过增加一个反向的 FPN (Feature Pyramid Network) 结构,增强模型的特征提取能力,提升了窗户识别的准确率,但检测速度有待提高;杨旭晖等^[6]基于 YOLOv2 算法通过添加卷积层、BN (Batch Normalization) 层设计出 YOLOv2 - TDDWNet (Traditional Dwelling Door and Window Net) 算法,大大提升了检测精度,但缺少对局部窗户的识别;洪恺临等^[7]基于 CenterNet 网络,替换原始卷积模块,引入注意力机制,提升了模型的检测速度和检测精度。

上述的检测方法虽然取得了一定效果,但模型复杂且计算量较大,窗户检测速度和检测精度都难以满足喷涂机器人的实际工作要求,无法部署在硬件条件有限的移动设备上。因此,设计一种适用于喷涂机器人的室内窗户检测算法对实现机器人自动化作业是十分有意义的。

本文设计了一种改进 YOLOv5s 的室内窗户检测算法,以满足喷涂机器人的应用需求。首先,用 PP-LCNet (Parallel Point-to-Line Convolutional Network) 网络替换 YOLOv5s 的主干网络部分,大大减少了网络的参数量和计算量,用 GhostNetv2 中的 Ghostv2 模块替换特征融合部分的 Conv 模块,构造 C3Ghostv2 模块替换 C3 模块,进一步简化模型,提升检测速度;其次,在主干网络末端添加基于 Transformer 编码器的 C3TR (C3 Transformer) 模块,提高模型的特征提取能力,降低了复杂背景对算法的干扰;最后,使用 SiLU 损失函数替换原损失函数,

加快预测框的收敛速度,提升模型的检测精度。

1 YOLOv5s 目标检测算法

YOLOv5s 网络因其准确率高和检测速度快等特点被广泛应用于目标检测领域。

YOLOv5s 网络结构如图 1 所示。YOLOv5s 主要是由特征提取 Backbone、特征融合 Neck 和检测层 Head 3 部分组成。网络 Backbone 部分由 Conv、C3、SPPF (Spatial Pyramid Pooling - Fast) 等模块组成,主要用于目标检测中的特征提取;Neck 层采用特征金字塔网络结构 (Feature Pyramid Network, FPN) 和路径聚合特征金字塔 (Path Aggregation Network, PAN) 结构,FPN 自顶向下增强了特征图的语义信息,PAN 自底向上增强了特征图的位置信息,两者相结合实现了上采样与下采样的特征融合;Head 层采用 CIoU 函数作为边界框的损失函数,用于判断检测目标的位置和特征,输出检测结果。

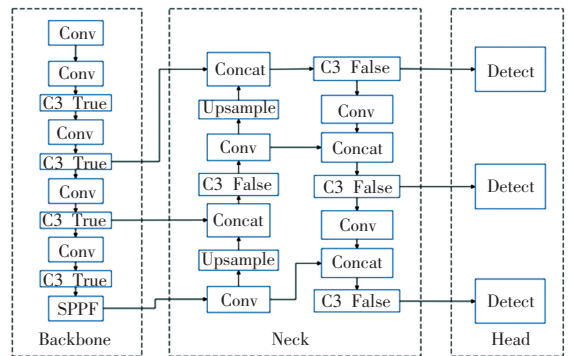


图 1 YOLOv5s 网络结构图

Fig. 1 Diagram of network structure for YOLOv5s

2 改进 YOLOv5s 网络结构

使用 PP-LCNet 网络替换 YOLOv5s 的主干网络部分;使用 GhostNetv2 网络来替代原网络特征融合部分中的普通卷积。

2.1 PP-LCNet 特征提取网络

PP-LCNet 是一种基于 MKLDNN (Math Kernel Library for Deep Neural Networks) 加速策略的轻量级 CPU 网络,使用深度可分离卷积 (DepthSepConv) 作为基础模块,采用 Hard-Swish 激活函数,大大减少模型的参数量和计算量,加快了网络的推理速度,并在末端卷积层添加 SE (Squeeze and Excitation) 注意力模块以增强对目标特征的获取,在轻量化的基础上仍保持着较高的检测精度,非常适合应用在硬件条件有限的室内喷涂机器人上,其结构如图 2 所示。

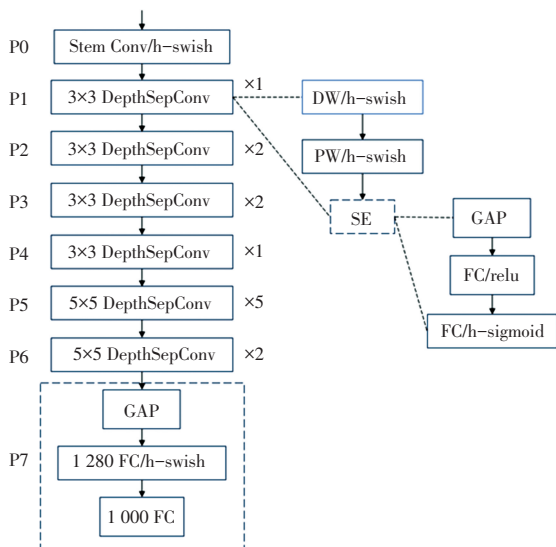


图 2 PP-LCNet 网络结构图

Fig. 2 Diagram of network structure for PP-LCNet

图 2 中 P7 部分主要用于图像分类,由一个全局平均池化层(GAP)和两个全连接层(FC)组成,由于本文是针对室内窗户的单目标检测,所以把这一部分删除,将剩余部分替换为 YOLOv5s 的网络主干,分别从 P3、P5 和 P6 的末端与网络特征融合部分相连。

2.2 GhostNetv2 特征融合网络

传统卷积网络为了得到比较全面的信息会产生大量相似的特征图,导致模型参数量大、计算时间长等问题。为进一步轻量化模型,本文在特征融合部分引入 Ghostv2 模块,其是在 Ghost 卷积的基础上结合解耦全连接(Decoupled Fully Connected, DFC)注意力机制构建而成的,具有动态校准与捕捉长距离空间信息的能力,能够在不损失检测精度的情况下,大幅度减小模型的参数量与计算量。

使用 Ghostv2 瓶颈模块来替代原网络特征融合部分中的普通卷积。当步长等于 1 时,输入特征首先经过 Ghostv2 卷积进行特征增强,然后通过 Ghost 卷积调整通道数量,得到输出特征。当步长等于 2 时,输入特征在经过 Ghostv2 卷积后,通过深度可分离卷积(Dwconv)调整尺寸大小,再经过一次 Ghost 卷积得到输出特征,其瓶颈模块结构如图 3 所示。

使用 C3Ghostv2 替代 Neck 层的 C3 模块,如图 4 所示。C3Ghostv2 将 C3 模块中的瓶颈部分替换为 n 个 Ghostv2 瓶颈模块,首先利用普通卷积生成基础特征图,经过批量归一化处理(BN)和 SiLU 激活函数后进入瓶颈结构提取特征;与普通卷积得到的特

征图进行拼接;最后,通过普通卷积调整通道数量得到输出特征图。

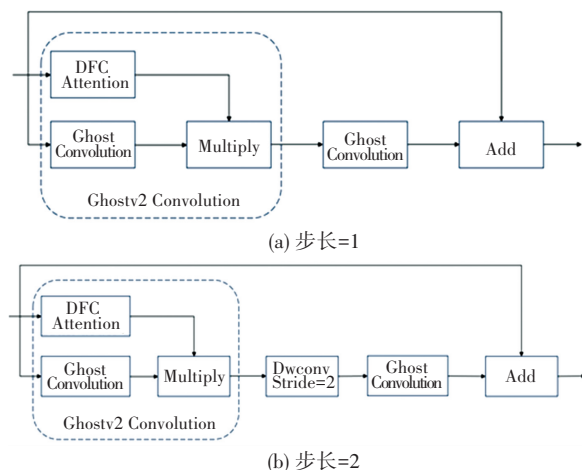


图 3 Ghostv2 瓶颈模块结构

Fig. 3 The structure of Ghostv2 Bottleneck module




图 4 C3Ghostv2 模块结构

Fig. 4 The structure of C3Ghostv2 module

2.3 Transformer 模块

为了更好的捕获检测目标的特征,提高算法检测的准确率,本文将 Transformer 编码器模块嵌入到 C3 模块中,构造成 C3TR 模块,其结构如图 5 所示。

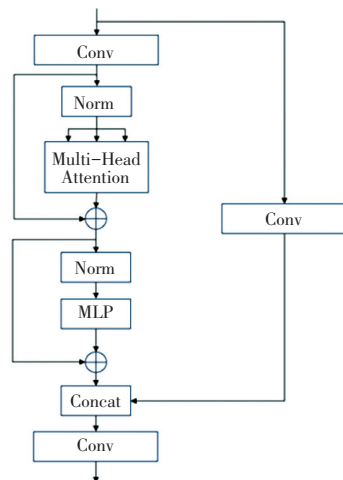


图 5 C3TR 模块结构

Fig. 5 The structure of C3TR module

Transformer 编码器主要由多头注意力层 MHA (Multi-Head Attention) 和多层感知器 MLP (Multi-

Layer Perceptron) 构成。MHA 可以根据输入图像的位置不同分配不同权重, 帮助网络捕获关键信息, 提供丰富的上下文特征; MLP 则通过对特征向量进行非线性变换和映射, 使得网络能够更好的收敛, 增强模型对室内窗户特征的表达能力。在室内窗户检测时, 窗户外复杂多变的环境会对检测过程产生干扰, 因此将 C3TR 模块添加到改进后的主干网络末端, 可以在几乎不增加存储成本的基础上帮助模型捕获全局空间关系, 增强其特征提取能力, 有助于模型更好的定位和识别窗户区域, 减小复杂环境对算法准确性的影响。

2.4 改进损失函数

YOLOv5s 采用 CIoU 损失函数, 虽然考虑到了真实框与预测框的重叠面积、框间距离和长宽比等, 但其长宽比一旦相同, 预测框的长和宽就不能同时增大或减小, 会对模型的继续优化产生影响。本文引入 SIoU 损失函数, 基于 CIoU 考虑了真实框与预测框的角度问题, 重新定义了角度损失、距离损失、形状损失和 IoU 损失。角度损失示意图如图 6 所示, 计算公式如式(1)~式(4)所示:




图 6 角度损失示意图

Fig. 6 Schematic diagram of angle loss

$$\Lambda = 1 - 2 \times \sin^2 \left(\arcsin x - \frac{\pi}{4} \right) \quad (1)$$

$$x = \frac{C_h}{\sigma} = \sin(\alpha) \quad (2)$$

$$\sigma = \sqrt{(b_{c_x}^{gt} - b_{c_x})^2 + (b_{c_y}^{gt} - b_{c_y})^2} \quad (3)$$

$$C_h = \max(b_{c_y}^{gt}, b_{c_y}) - \min(b_{c_y}^{gt}, b_{c_y}) \quad (4)$$

其中, σ 代表真实框与预测框的中心点距离; C_h 代表真实框与预测框的中心点在 y 方向上的距离; b^{gt} 、 b 代表真实框和预测框的中心点坐标。

距离损失 Δ , 计算为式(5)~式(8):

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma p_t}) \quad (5)$$

$$p_x = \left(\frac{b_{c_x}^{gt} - b_{c_x}}{C_w} \right)^2 \quad (6)$$

$$p_y = \left(\frac{b_{c_y}^{gt} - b_{c_y}}{C_h} \right)^2 \quad (7)$$

$$\gamma = 2 - \Lambda \quad (8)$$

其中, C_w 和 C_h 代表预测框与真实框最小外接矩形的宽和高。

形状损失 Ω , 计算为式(9)~式(11):

$$\Omega = \sum_{t=w,h} (1 - e^{-w_t})^\theta \quad (9)$$

$$w_w = \frac{|w - w^{gt}|}{\max(w, w^{gt})} \quad (10)$$

$$w_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \quad (11)$$

其中, w^{gt} 、 h^{gt} 和 w 、 h 分别代表真实框与预测框的宽、高。

SIoU 的数学定义为式(12):

$$L_{SIoU} = 1 - IoU + \frac{\Delta + \Omega}{2} \quad (12)$$

预测框与真实框的交并比 IoU , 式(13):

$$IoU = \left| \frac{B \cap B^{gt}}{B \cup B^{gt}} \right| \quad (13)$$

使用 PP-LCNet 和 GhostNetv2 网络对模型进行轻量化改进, 引入 Transformer 编码器增强模型对全局信息的提取, 提高模型准确率, 使用 SIoU 损失函数解决预测框与真实框角度不匹配问题, 加快网络的收敛速度, 提升检测精度, 改进后的 YOLOv5s 网络结构如图 7 所示。

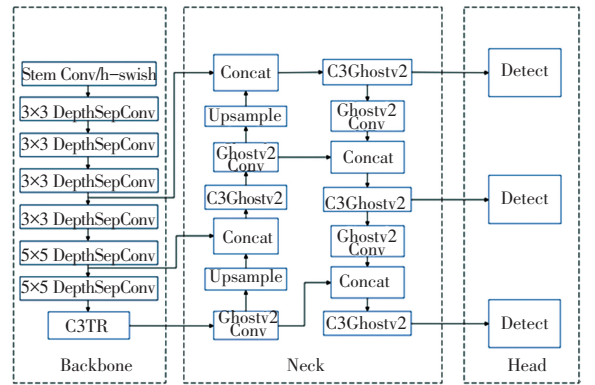


图 7 改进的 YOLOv5s 网络结构图

Fig. 7 Diagram of network structure for improved YOLOv5s

3 实验结果与分析

3.1 实验环境

本实验训练阶段的主机环境: CPU 型号为 Intel (R) Core (TM) i5-11400H@2.70 GHz, GPU 型号为 NVIDIA GeForce RTX 3050 Ti, CUDA 版本为 11.6, 在 Windows 11 系统环境下进行训练, 使用 pytorch1.12.0 作为深度学习框架, python 版本为 3.7.16。

测试阶段则使用喷涂机器人搭载的移动端处理器验证该算法的准确性与实用性,采用 Intel(R) Core(TM) i7-8700 CPU @ 3.20 GHz 中央处理器。

3.2 数据集

由于室内窗户没有公开的数据集,所以本文通过网络爬虫和喷涂机器人搭载的摄像头现场拍摄,共得到 1 350 张室内窗户图片,其中包含不同光照条件和具有复杂背景的完整窗户图片和局部窗户图片。训练前使用 Labelme 软件对窗户进行标注并转换为 .json 格式保存。由于 YOLOv5 只识别 .txt 文本文件,所以还需要将标注文件由 .json 格式转换为 .txt 格式,并将最终得到的室内窗户数据集按照 8 : 1 : 1 的比例随机划分成训练集、验证集、测试集。

参数设置:初始学习率为 0.01,动量系数为 0.937,权重衰减系数为 0.000 5, batch size 设置为 8,训练 200 个 epoch,采用 SGD (Stochastic Gradient Descent) 作为优化器,输入图片尺寸为 640×640,采用 Mosaic 数据增强方式来提高网络的泛化能力。

3.3 评价指标

本实验采用平均精度均值 (mAP)、参数量 ($Params$)、计算量 ($FLOPs$)、权重 ($Weights$) 以及检测速度 (FPS) 作为模型性能的评估指标。 $mAP@0.5$ 是 IOU 阈值为 0.5 时,召回率 ($Recall, R$) 和精确率 ($Precision, P$) 为横纵坐标的曲线与坐标轴之间的面积,是目标检测性能的主要评价指标;参数量是衡量模型大小的重要指标,过大的参数量会占用大量内存,无法应用到机器人的嵌入式系统中;计算量是指浮点运算次数,用来衡量模型的复杂程度,计算量越小,模型越简单;权重表示模型权重数大小,权重越小,越易于部署在设备条件有限的机器人上;检测速度是指模型每秒可以推理的图片帧率,检测速度越快,机器人的识别效率越高。精确率、召回率、平均精度均值计算为式(14)~式(16):

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$mAP = \int_0^1 P(R) d(R) \quad (16)$$

其中, TP 表示算法预测和人工标注均为正样本的数量; FP 表示算法预测为正样本但人工标注为负样本的数量; FN 表示算法预测为负样本但人工标注为正样本的数量。

3.4 轻量化对比实验

轻量化对比实验结果见表 1。可以发现使用 ShuffleNetv2 作为主干网络的模型更加简单,但是其 mAP 值明显下降,不符合本文检测精度要求。相比之下,使用 PP-LCNet 模型的参数量、计算量和权重大小不仅低于 MobileNetv3 模型,而且其 mAP 值是 3 个轻量化主干网络中最高的。改进后的模型比原始 YOLOv5s 算法参数量减少了 5.45 M、计算量减少了 12.6 G,权重体积缩小了 10.9 MB,并且其 mAP 值提高了 0.4%,证明本文对网络结构的改进可以在不损失精度的情况下实现模型的轻量化。

表 1 轻量化对比实验结果

Table 1 Light weight comparison experiment results

模型	评价指标			
	Param/ M	Weights/ MB	FLOPs/ G	$mAP@0.5$
YOLOv5s	7.01	14.4	15.8	94.4
ShuffleNetv3	2.87	6.1	5.6	77.1
MobileNetv3	3.36	7.1	5.9	94.6
PP-LCNet	2.92	6.2	5.7	94.3
Ghostv2	5.43	11.6	12.4	97.2
PP-LCNet + Ghostv2	1.56	3.5	3.2	94.8

3.5 消融实验

本文算法从特征提取、特征融合和损失函数三方面对 YOLOv5s 进行改进,为了验证各个改进部分对室内窗户检测的影响,设计了消融实验,实验结果见表 2。

表 2 消融实验结果

Table 2 Ablation experiment results

模型	评价指标			
	Param/ M	FLOPs/ G	$mAP@0.5$	FPS
YOLOv5s	7.01	15.8	94.4	9
YOLOv5s+PP-LCNet+GhostNetv2	1.56	3.2	94.8	16
YOLOv5s+ PP-LCNet+GhostNetv2+C3TR	1.56	3.2	96.4	16
YOLOv5s+PP-LCNet+GhostNetv2+SiOU	1.56	3.2	95.8	16
YOLOv5s+ PP-LCNet+GhostNetv2+C3TR+SiOU	1.56	3.2	97.3	16

使用 PP-LCNet 和 GhostNetv2 两个轻量化网络分别改进 YOLOv5s 的特征提取和特征融合部分,可以在不损失精度的情况下压缩模型的参数量和计算量,并且大大提升了检测速度。在改进后的主干网络末端添加基于 Transformer 编码的 C3TR 模块,进

进一步增强模型的特征提取能力,其参数量和计算量几乎没有增加,而 $mAP@0.5$ 提升了 2%。使用 SIoU 损失函数替换原 CIoU 损失函数,其解决了预测框与真实框的长宽比相同时无法同时增大或减小的问题,加快了模型的收敛速度, $mAP@0.5$ 相较于原网络增加了 1.4%。最终模型取得了较好的效果,参数量和计算量分别下降了 5.45 M 和 12.6 G, $mAP@0.5$ 提升了 2.9%,而 FPS 增加至 16 帧/S,在实现模型轻量化的同时提升了检测精度,满足部署在资源有限的移动设备中的需求。

改进后算法与原算法的 $mAP@0.5$ 曲线对比图如图 8 所示,可以看出改进后模型的收敛速度更快,曲线波动幅度更小,最终 mAP 值更高,说明改进模型更加稳定高效,可以在短时间内达到较高的检测精度。




图 8 算法改进前后 $mAP@0.5$ 对比图

Fig. 8 Comparison of $mAP @ 0.5$ before and after model improvement

改进前后的目标检测损失曲线对比如图 9 所示,可以看出改进后模型的损失值下降更快,最终收敛值更低,说明对损失函数的改进有效的增强了原算法的收敛能力。

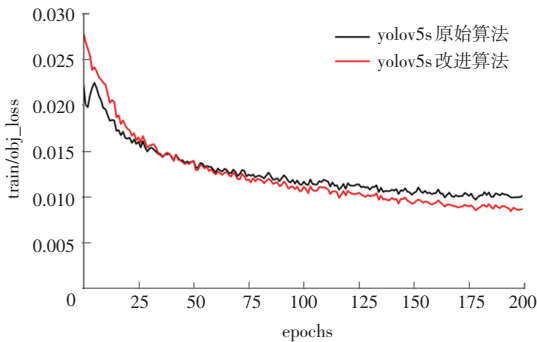


图 9 算法改进前后损失曲线对比

Fig. 9 Comparison of loss before and after model improvement

3.6 检测结果对比

使用改进算法和原 YOLOv5s 算法检测窗户得到的对比图,展现了在不同环境与光照条件下室内

窗户的检测情况如图 10~图 13 所示。

由图 10 可知,改进算法在检测特殊外形的窗户时具有更强的识别能力,解决了原算法的漏检问题;在图 11 中,原算法错将窗户外楼顶识别为窗户的上边缘,而改进算法则正确检测出了完整窗户,说明改进模型具有更强的抗干扰能力;图 12 和图 13 是在不同光照条件下的完整窗户和局部窗户检测图,可以看出改进算法比原算法有着更高的检测精度,无论是整体窗户还是局部窗户都被精准的检测出来。



(a) 改进前 (b) 改进后

图 10 特殊外形的窗户识别对比

Fig. 10 Comparison of window recognition with special shape



(a) 改进前 (b) 改进后

图 11 复杂背景下局部窗户识别对比


Fig. 11 Comparison of local window recognition in complex background



(a) 改进前 (b) 改进后

图 12 逆光条件下窗户识别对比图

Fig. 12 Comparison of window recognition under backlight conditions



(a) 改进前

(b) 改进后

图13 昏暗条件下局部窗户识别对比图

Fig. 13 Comparison of window recognition under dim conditions

3.7 不同检测算法对比

为更好的说明改进后 YOLOv5s 算法的优势,选用现有的主流目标检测算法 YOLOv4-tiny、YOLOv5s、YOLOv6s、YOLOv7-tiny 和本文改进算法在同一数据集下进行对比实验,实验结果见表3。

表3 不同算法检测结果对比

Table 3 Comparison of test results on different algorithms

模型	评价指标			FPS
	Param/ M	Weights/ MB	mAP@0.5	
YOLOv4-tiny	6.12	22.3	91.6	7
YOLOv5s	7.01	14.4	94.4	9
YOLOv6s	18.24	44.8	94.9%	10
YOLOv7-tiny	6.17	12.3	94.6%	12
Ours	1.56	3.5	97.3	16

由表3可知,改进算法在参数量、模型大小和检测速度上均优于其它算法,改进算法的 $mAP@0.5$ 相比于 YOLOv4-tiny、YOLOv6s、YOLOv7-tiny 和 YOLOv5s 网络分别提升了 5.7%、2.4%、2.7% 和 2.9%。综上所述,本文改进算法在保持轻量化的基础上,有效提升了模型的检测精度和检测速度,满足室内喷涂机器人的实际应用要求。

4 结束语

本文为喷涂机器人设计了一种改进 YOLOv5s 的室内窗户检测算法,使用 PP-LCNet 网络和 GhostNetv2 网络与 YOLOv5s 相结合实现模型的轻量化,在主干网络中引入基于 Transfoemer 模块构建的 C3TR 模块来提升模型对室内窗户的特征提取能力,使用 SIoU 损失函数来加快网络的收敛速度,提升检测精度。实验结果表明,最终优化后的模型相比较原 YOLOv5s,其 $mAP@0.5$ 值提升了 2.9%,参数量减少了 77.7%,检测速度提升了 77.8%,权重文件减小了 75.7%。在喷涂机器人上经过实际验证,该算法对于不同光照条件和复杂背景环境下的完整窗户与局部窗户都有着良好的检测效果。然而本次研究没有考虑到施工现场粉尘和喷涂时产生的雾气对窗户检测的影响,在后面的工作中,将进一步丰富室内窗户数据集,通过去雾化处理进一步优化算法。

参考文献

- [1] 孔倩倩,赵辽英,张莉. 基于图像轮廓分析的室内窗户检测[J]. 计算机与现代化,2018, 272(4):56-61.
- [2] Neuhausen M, Martin A, Obel M, et al. A cascaded classifier approach to window detection in facade images [C]//ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction. IAARC Publications, 2017: 34.
- [3] 高云龙,张帆,屈孝志,等. 结合样本自动选择与规则性约束的窗户提取方法[J]. 武汉大学学报(信息科学版),2018,43(3): 436-443.
- [4] MA Wenguang, MA Wei. Deep window detection in street scenes [J]. KSII Transactions on Internet and Information Systems (TIIS), 2020, 14(2): 855-870.
- [5] 张祖宇,孙时钟,温久民,等. 基于倾斜三维数据的建筑物分层方法[J/OL]. 测绘地理信息,1-6[2023-11-27]. <http://doi.org/10.14188/j.2095-6045.2021422>.
- [6] 杨旭晖,余亮,唐铭婕,等. 基于改进 YOLOv2 的山西传统民居门窗识别方法研究[J]. 建筑与文化,2020(10):65-67.
- [7] 洪恺临,曹江涛,姬晓飞. 改进 Center-Net 网络的自主喷涂机器人室内窗户检测[J]. 智能系统学报,2021,16(3):425-432.