

改进 YOLOv8n 的轻量化仓储多目标检测算法研究

祖绍彭¹, 杨秋菊², 吐尔逊·买买提¹, 段 婷², 刘志国², 周文亮¹, 刘相铄¹

(1. 新疆农业大学 交通与物流工程学院, 新疆 乌鲁木齐 830052;

2. 新疆交通建设集团股份有限公司, 新疆 乌鲁木齐 830063)

摘 要: 多目标检测算法是能够在单幅图像中同时识别并定位多个目标的计算机视觉方法, 在自动驾驶、智能交通、和仓储物流等场景中具有广泛应用。为了满足智能仓储机器人对目标检测的实时性和准确性的需求, 构建了一种改进的轻量化仓储目标检测算法(YOLOv8n-DFL)。首先, 利用扩张加权残差(DWR)模块优化 C2f 模块, 该模块通过不同扩张率卷积实现多尺度特征提取, 并结合残差结构保证稳定性; 其次, 构建轻量化特征聚焦扩散金字塔网络(LFDPN), 在结构上引入并行深度卷积, 以充分挖掘不同尺度的表征特征, 并结合特征扩散策略将信息传递至各检测层, 从而提升不同尺度间的特征协同能力; 最后, 引入轻量化检测头(LSCD), 使用共享卷积的方式以减少模型计算量和参数量。根据消融实验结果可知, 相较于原始 YOLOv8n 模型, 改进算法的 mAP@0.5、mAP@0.5:0.95 和召回率分别提升了 1.3%、0.4% 和 1.5%, 同时模型参数量减少了 23.92%, 计算量仅 7.2 GFLOPs, 较原模型下降 11.11%。研究表明, 改进模型能够为仓储目标检测提供一种轻量化的检测方法。

关键词: 仓储环境; 目标检测; YOLOv8n; 模型轻量化; 特征提取; 多尺度融合

DOI: 10. 11907/rjdl. 251655

扫描二维码阅读全文: 

中图分类号: TP391.41

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-10

Lightweight Multi-Object Detection in Warehouse Environments Using an Improved YOLOv8n Algorithm

ZU Shaopeng¹, YANG Qiuju², TURSUN Mama¹, DUAN Ting², LIU Zhiguo², ZHOU Wenliang¹, LIU Xiangshuo¹

(1. School of Transportation and Logistics Engineering, Xinjiang Agricultural University, Urumqi 830052, China;

2. Xinjiang Transportation Construction Group Co., Ltd, Urumqi 830063, China)

Abstract: A multi-object detection algorithm is a computer vision approach that can simultaneously identify and localize multiple objects within a single image, and it has been widely applied in scenarios such as autonomous driving, intelligent transportation, and warehouse logistics. To meet the real-time and accurate object detection requirements of intelligent warehouse robots, an improved lightweight warehouse object detection algorithm (YOLOv8n-DFL) was constructed. First, the C2f module was optimized using the Dilated Weighted Residual block (DWR). This module uses convolutions with different dilation rates to extract multi-scale features and incorporates a residual structure to ensure stability. Second, a lightweight feature-focused diffusion pyramid network (LFDPN) was constructed. This architecture incorporates parallel depthwise convolutions to fully exploit representational features at different scales. This information is then transferred to each detection layer using a feature diffusion strategy, thereby enhancing the synergy between features at different scales. Finally, a lightweight detection head (Lightweight Shared Convolutional Detection Head (LSCD)) was introduced, utilizing shared convolutions to reduce the model's computational overhead and parameter count. Ablation experiments show that compared to the original YOLOv8n model, the improved algorithm improves mAP@0.5, mAP@0.5:0.95, and recall by 1.3%, 0.4%, and 1.5%, respectively. The model also reduces parameters by 23.92%, and the computational overhead is only 7.2 GFLOPs, a 11.11% decrease compared to the original model. This improved model provides a lightweight detection method for warehouse objects.

Key Words: warehouse environment; object detection; YOLOv8n; model lightweight; feature extraction; multi-scale fusion

收稿日期: 2025-09-19

基金项目: 自治区重点研发计划项目(2022B01013-2); 新疆农业大学研究生校级科研创新项目(XJAUGRI2025048)

作者简介: 祖绍彭(2001-), 男, 新疆农业大学交通与物流工程学院硕士研究生, 研究方向为智能交通; 杨秋菊(1991-), 女, 硕士, 新疆交通建设集团股份有限公司高级工程师, 研究方向为智慧物流、公路工程; 吐尔逊·买买提(1975-), 男, 博士, 新疆农业大学交通与物流工程学院副教授、硕士生导师, 研究方向为智能交通、计算机算法。本文通讯作者: 吐尔逊·买买提。

0 引言

2024年,全国社会物流总额达到360.6万亿元,比上年增长5.8%,物流业规模持续扩大并加快向智能化转型^[1]。随着物流业的快速发展,其对自动化和智能化的需求不断增加,同时在仓储环节暴露出人工成本高、效率低下、环境复杂等问题。传统目标检测方法多依赖手工特征加分类器模型,对光照、遮挡、尺度变化敏感,在仓储等背景复杂、目标密集的环境下泛化不足,并且难以满足轻量化、准确性和实时性需求。尤其是仓储场景中的目标呈现密集分布、尺度差异大和背景复杂的特征,使得高效可靠的自动化检测技术成为行业发展的迫切需求。因此,多目标检测技术在仓储场景中的应用变得尤为重要,将目标检测技术与仓储环境结合,不仅能够为智能仓储机器人提供可靠的避障与物品检索支持,还能有效降低仓储环节的人力与物力投入,推动仓储管理智能化和自动化发展,具有重要的应用价值和现实意义。

目标检测领域的大多算法都是基于深度学习加以实现。目前,国内外主流的基于深度学习的目标检测算法有单阶段目标检测算法和双阶段目标检测算法^[2]。其中,单阶段目标检测算法包括SSD、YOLO等,YOLO网络因其高检测速度和准确性而备受关注^[3-4]。然而,在复杂的仓储场景中,货物目标普遍存在尺寸差异大、摆放密集、小目标占比较高以及背景干扰复杂等问题,使得传统的YOLO检测算法难以在实际应用中取得理想效果。当前,目标检测任务多倾向于采用单阶段检测算法。陈亮杰等^[5]提出一种基于SSD的仓储物体检测算法,采用VGG16网络进行图像特征提取,基本实现了仓储物体准确检测,但对于较小的仓储物体仍会出现漏检。王晨等^[6]提出一种可用于智能仓储机器人的轻量化仓储货物检测方法,引入MobileNetv3重构特征提取网络,融入改进的CBAM模块,并采用具有膨胀卷积的残差结构扩大空间注意力模块中的感受野。改进后的E-YOLOv4-Lite模型具有精度高、实时性好和轻量化的优点。刘辉等^[7]提出一种基于YOLOv8n的轻量化PCB检测算法ST-YOLO,该算法采用轻量化主干网络StarNet替换YOLOv8n的主干网络,调整网络结构,将颈部网络中C2f模块与StarBlock和CA注意力机制相结合设计出C2f-Star-CA模块,并设计轻量化检测头,在保持高精度的同时实现了轻量化,但是需要开发者在边缘设备部署的过程中为其单独实现GPU算子程序。蒋康等^[8]提出一种改进YOLOv8的轻量化车辆目标检测算法,采用改进的REPELAN模块替换C2f模块,使用一种轻量化共享卷积检测头取代原始检测头,在骨干网络中引入坐标注意力机制,使用WISE-IoU损失函数替换YOLOv8网络中的原CI-OU损失函数,提高了车辆目标检测模型的整体性能,降低了模型的参数量与体积,但对小目标的检测精度不足。

双阶段目标检测算法主要包括R-CNN^[9]、Faster R-CNN^[10]等。检测过程首先需生成大量候选框,再对其进行识别,因而这类算法的检测效率较低,且网络较为复杂,不符合智能仓储机器人的实时性需求^[11]。周诗捷等^[12]提出一种基于改进型Faster R-CNN的仓储环境物体识别算法,采用ResNet50替换VGG16作为特征提取网络,引入了特征金字塔网络和注意力机制,并使用RoI Align代替原有的RoI Pooling,提高了预测框的精确度,但实时性较差。李映松等^[13]提出基于Transformer改进的Faster R-CNN仓储箱体检测模型,使用Swin Transformer进行全局信息提取,引入了特征金字塔结构,并使用ROI Align代替ROI Pooling,较好地实现了仓储箱体的准确检测,但模型参数量较大。金秋等^[14]提出一种基于Faster-RCNN优化和改进后的物体识别算法,改进和优化后的算法对仓储环境下物体检测准确率达到90%,测试的帧率为33.3 fps,基本满足叉车机器人对物体检测实时性和准确性的要求。Zaccaria等^[15]提出一种基于卷积神经网络并结合决策制定步骤的方法,利用单个RGB相机实现工业环境下的自动托盘检测,以服务于AGV导航及托盘存储和检索任务。Rutinowski等^[16]利用基于深度学习的计算机视觉方法,实现物流单元的多视角位姿估计,用于在工厂内对其进行跟踪与定位。

当前,基于深度学习的仓储物体检测逐渐成为一个新兴的研究领域,但现有研究中针对仓储多物体检测的研究还相对较少。针对仓储环境下存在着多个目标的高密度分布和小目标检测难度等问题,同时实现更好的移动端部署,需要选择适合的轻量化模型。基于此,本文提出了一种改进YOLOv8n的轻量化仓储环境多目标检测算法,实现了仓储目标检测在精度与轻量化之间的有效平衡,为智能仓储场景的实时检测提供了一种可行的解决方案。本文研究从3个方面对YOLOv8算法进行了改进:①在YOLOv8主干网络中引入扩张加权残差(Dilated Weighted Residual block, DWR)模块,替换原C2f结构,利用不同膨胀率卷积增强多尺度特征建模能力,提升了对复杂仓储场景的适应性;②构建轻量化特征聚焦扩散金字塔网络(Lightweight Feature-focused Diffusion Pyramid Network, LFDPN),通过特征扩散机制与聚焦模块强化不同层级特征间的交互,有效改善了小目标与密集目标的检测效果;③利用轻量化检测头(Lightweight Shared Convolutional Detection Head, LSCD)替换原YOLOv8检测头,通过共享卷积与解耦预测减少计算量与参数规模,在保证精度的同时提升了模型推理效率和收敛速度。

1 YOLOv8算法

YOLOv8是近年来提出的先进单阶段目标检测框架,其在保持较高检测精度的同时具备优良的推理效率。根据网络宽度与深度的复合缩放策略,官方提供了YO-

LOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x 5 个规格,用以覆盖从资源受限到高性能计算等不同应用场景。YOLOv8n的网络结构主要包括主干网络(Backbone)、颈部网络(Neck)和检测头(Head)3个部分^[17]。其中,YOLOv8n在参数量与计算量方面最为轻量,兼顾了速度与精度,更易于在嵌入式或边缘设备上部署,满足实时性与功耗约束。与YOLOv11模型相比,YOLOv8模型结构清晰、轻量化特征明显,更适合本文的仓储目标检测任务。此外,YOLOv8模型经过广泛验证,更有助于保证实验结果的可靠性与对比试验的公平性。因此,本文选取YOLOv8n作为基线模型,以在检测性能与部署可行性之间取得合理平衡。YOLOv8网络模型的完整结构如图1所示。




Fig. 1 YOLOv8n network architecture

图1 YOLOv8n网络结构

2 YOLOv8n模型改进

2.1 改进的YOLOv8n模型结构

YOLOv8n使用大量的标准卷积与C2f模块,虽然提升了检测精度,但也增加了参数规模和计算开销。并且,仓储环境中目标图像背景复杂,模型在特征提取与融合过程中易受干扰,从而导致检测性能下降。针对上述问题,本文对YOLOv8n进行了改进:首先,在Backbone中引入可扩张残差模块以优化C2f结构,提升多尺度上下文信息的获取效率;其次,设计轻量化特征聚焦扩散金字塔网络(LF-SPN),通过特征扩散机制将语义丰富的特征自适应分配到不同检测层级,增强特征表达能力;最后,优化检测头结构,提升模型鲁棒性和检测效果。YOLOv8n-DFL模型结

构如图2所示。

2.2 C2f-DWR模块

本文在YOLOv8n的基础上引入了扩张加权残差模块,取代原来的Bottleneck模块。传统的Bottleneck主要由标准卷积组成,在特征建模方面存在一定局限性,难以充分提取不同大小目标所需的空间信息。相比之下,DWR模块在设计中引入了具有不同膨胀率(dilation rates=1、3、5)的卷积层,能够在同一层级上同时捕捉不同感受野下的上下文信息,从而有效增强模型的多尺度特征表达能力,提升对小目标与大目标的兼顾性能。值得注意的是,虽然DWR模块在结构上引入了更多卷积层,但其核心优势在于利用了膨胀卷积的特性:在保持参数量与计算量相对可控的前提下显著扩大了感受野,避免了传统深层卷积堆叠带来的计算资源消耗。因此,该模块不仅增强了特征提取的丰富性和鲁棒性,同时保证了轻量化检测模型在实际应用中的部署可行性。相关结构示意图如图3所示。

DWR模块以残差方式设计,如图4所示。它接收一个通道数为dim的输入张量,经过以下处理流程:

(1)通道压缩与初步特征提取。输入首先通过一个标准的3×3卷积层,通道数从dim减半(变为dim/2),用于降低计算复杂度并提取局部特征。

(2)多尺度特征提取(使用扩张卷积)。将压缩后的特征分别送入3个具有不同扩张率的3×3卷积中:普通卷积(扩张率 $d=1$)提取局部细节;中等扩张卷积($d=3$)提取中尺度上下文;大扩张卷积($d=5$)捕获更大范围的结构特征。

(3)通道拼接与融合。将上述3个不同尺度提取的特征在通道维度拼接,合并为一个通道数为 $2 \times \text{dim}$ 的张量。随后,通过一个1×1卷积将通道数重新压缩回原始维度dim,实现多尺度特征的融合。

(4)残差连接。将融合后的输出与输入进行逐元素相加,形成残差连接,以增强特征表达的稳定性 and 深度信息传递能力。

2.3 改进的LFDPN结构

特征金字塔网络(Feature Pyramid Network, FPN)作为YOLOv8核心架构中的关键组件,在多尺度特征的整合与利用中发挥着重要作用。其自上而下的路径结构能够有效融合不同层级的语义与空间信息,从而提升检测模型对各类目标的感知能力。在仓储环境的目标检测任务中,特征金字塔网络结构容易忽略关键特征图,从而造成精度下降。针对该问题,本文设计了LFDPN架构,通过引入特征聚合与扩散机制以优化多尺度特征的融合。根据表1的实验数据选择了主干网络的P3、P4和P5 3个层级特征作为输入。相比之下,P2层过浅,容易引入噪声;而P6层过深,细节严重丢失,因此未被采用。

首先,P3、P4、P5捕捉的3个不同尺度特征图作为输入。P3:分辨率最高、语义最浅的特征(适用于小目标);P4:中间层特征;P5:语义最强但分辨率最低的特征(适用




Fig. 2 YOLOv8n-DFL network architecture

图2 YOLOv8n-DFL网络结构




Fig. 3 Comparison of C2f structures before and after incorporating the DWR module

图3 融合DWR模块前后的C2f结构对比

于大目标)。FocusFeature 模块用于聚焦和增强多尺度特征图之间的上下文信息,通过大核卷积、多尺度提取和残




Fig. 4 DWR module

图4 DWR模块

差连接,实现更丰富的特征表示。

P3、P5层的原始特征分别与 FocusFeature 模块输出的结果进行处理,其过程为通过上采样和 3×3 卷积操作实现多分辨率特征的聚合,以提升模型在不同尺度目标检测上

Table 1 Ablation experiments results of different feature layer combinations

表 1 不同特征层融合的消融实验结果 (%)			
层级	mAP@0.5	Precision	Recall
P2-P4	65.3	70.1	64.5
P3-P5	66.1	72.5	66.3
P4-P6	64.4	69.3	65.9

的表现。C2f 模块进一步融合各层特征,对拼接后的特征

图进行优化,使信息更加集中。随后,将经过 C2f、Focus-Feature 以及上采样处理后的特征一并输入下一级 Focus-Feature 模块,完成新的特征聚合,并结合扩散机制将包含丰富上下文的特征向不同检测层传播,实现强化整体特征表达能力的目的。通过上述设计,LFDPN 能够有效解决原始模型在复杂场景下因关注不足而造成的漏检与误检问题,其整体实现框架如图 5 所示。




Fig. 5 Architecture of the feature-focused diffusion pyramid network (FDPNet)

图 5 特征聚焦扩散金字塔网络结构

由图 6 可知,FocusFeature 模块接收多个不同层级(或来源)的特征图。来自 P3 的输入:先下采样(Down);来自 P5 的输入:先上采样(Upsample)。利用 Conv 对齐通道或形状,拼接后的特征图被送入多个不同尺寸的深度可分离

卷积(DWConv)。所有 DWConv 输出与 Identity 分支进行逐元素相加(Add),再使用一个 1×1Conv 以压缩通道、融合信息。




Fig. 6 Feature focus module(FFM)

图 6 特征聚焦模块

2.4 检测头改进

YOLOv8 中的检测头采用解耦头结构,分为两个分支,分别用来计算分类损失和锚框损失,为了实现多尺度检测,采用了大、中、小 3 个检测头,每个检测头都有多个卷积层堆叠、特征融合等操作,这使得参数量大幅增加,单个原始检测头网络结构如图 7 所示。




Fig. 7 Original YOLOv8 detection head structure

图 7 原 YOLOv8 检测头结构

引入 LSCD (Lightweight Shared Convolutional Detection Head) 检测头更换原始检测头, 在 LSCD 中通过使用组归一化层 (Group Norm) 代替原卷积模块中的批量归一化层 (BatchNorm2d), 组成 Conv_GN 模块。与 Conv 结构比较如图 8 所示, 能够有效提升检测头定位和分类性能。




Fig. 8 Comparison between Conv and Conv_GN structures

图 8 Conv 和 Conv_GN 结构比较




Fig. 9 LSCD structure

图 9 LSCD 结构

3 实验与结果分析

3.1 实验环境与实验参数

实验采用 Microsoft Windows11 专业版操作系统, 硬件配置包括 Intel (R) Core (TM) i7-10700CPU (主频 2.90 GHz)、48 GB 内存, 以及 NVIDIA GeForce RTX4090 图形处理器。编程环境基于 Python3.10, CUDA 版本为 12.1, 深度学习框架采用 PyTorch2.1.2。实验训练过程中, 各项超参数具体设置如表 2 所示。

Table 2 Training parameter settings

表 2 训练参数设置

参数名称	参数设置	参数名称	参数设置
Optimizer	Adam	workers	4
epochs	200	IoU	0.7
patience	50	lr0	0.001
batch	16	lrf	0.01
imgsz	640	momentum	0.937

LSCD 检测头模块接收来自特征聚焦扩散金字塔网络 (LFDPN) 的 3 组不同尺度的特征图 P3、P4 和 P5, 分别表示高分辨率 (适合检测小目标)、中等分辨率和低分辨率 (适合大目标) 的特征。分别通过一个 1×1 卷积, 统一通道数, 并结合 GN (Group Normalization) 作归一化处理, 确保特征分布一致。共享特征增强卷积特征图经过归一化后, 依次通过两层共享的 3×3 卷积+GN, 用于增强局部空间上下文信息。使用共享卷积的方式能够减少参数量, 同时保持一致的特征抽象过程。每个尺度的特征图都会分成两个支路进行输出, 为了应对每个检测头检测目标尺度不一致的问题, 使用 Scale 层对特征进行缩放, 使检测头在参数量和计算量减少的情况下尽可能减少精度损失。LSCD 结构如图 9 所示。

3.2 实验数据集

在仓储物品检测领域, 公开的数据集很少^[18]。该实验所采用数据集为自制数据集, 包括两部分: ①从公开数据集获取并重新标注; ②从谷歌上爬取的相关图片。部分仓储训练集如图 10 所示。

数据集标注采用开源标注软件 LabelImg 对仓储场景图片进行人工标注。标注时, 首先以目标物体的最小外接矩形作为真实框 (ground truth box), 并生成对应的 XML 格式标注文件; 其次, 对初步得到的数据集进行检验与清理, 剔除存在标注偏差或错误的图像样本; 最后, 将处理后的数据集转换为符合 COCO 标准的数据格式, 以便后续模型训练与评估。数据集包含叉车 (forklift)、托盘 (pallet)、托盘搬运车 (pallet truck)、小型载货车 (small load carrier)、货架 (stillage) 共计 5 类检测对象, 图像中的目标存在着尺度差异大、光照条件差异和分布密集等特点, 导致数据集检测背景复杂。数据集共计 4 801 张图片, 标注物体实例共 29 743 个, 按 7:2:1 的比例划分为训练集、验证集和测试集, 标签分布情况如图 11 所示。



Fig.10 Sample images from the warehouse training set

图 10 部分仓储训练集图像

所示。

$$AP@α = \int_0^1 P(r)dr \quad (3)$$

其中, $P(r)$ 代表精度—召回曲线。对每个类别都可以计算单独的 AP, 然后对所有 k 个类别的 AP 取平均, 得到平均精度均值 (mAP), 计算公式如式 (4) 所示。

$$mAP@α = \frac{1}{k} \sum_{i=1}^k AP \quad (4)$$

其中, 符号 $mAP@α$ 表示在特定的 IoU 阈值下评估的 mAP。例如, $mAP@0.5$ 表示在 IoU 阈值为 0.5 时计算的 mAP, k 代表类别总个数。

效率指标衡量模型在计算复杂度、模型大小和实时推理速度方面的性能, 包括浮点运算量 (FLOPs)、参数规模 (Params)、模型权重大小 (Weight)、和帧率 (Frame/s)。FLOPs 通过计算模型所需的浮点运算次数衡量计算复杂性, 较少的 FLOPs 意味着更高的计算效率。Params 表示模型中可学习参数的数量, 参数较少的模型更轻量化, 更适合在资源受限的设备上运行。帧率衡量模型推理速度, 即模型每秒能够处理的帧数。

3.4 实验结果分析

为了检验模型综合性能, 本文设计两类实验: ①消融实验, 验证本文模型不同模块的有效性; ②与经典算法对比, 本文主要与 YOLOv3-tiny、YOLOv5n、YOLOv8s、YOLOv10n 和 YOLOv5-CE 的训练过程和检测精度作对比。

3.4.1 消融实验

本文采用模块化消融策略进行对比实验, 通过逐项激活核心改进模块分析其性能增益, 具体实验结果如表 3 所示。可以看出, 模型 1 在主干部分的 C2f 层融合 DWR 模块, 动态加权残差机制优化特征融合, 提升模型在密集场景下提取关键特征的能力, 同时避免了计算量的增加, 使参数量下降了 0.06 M, 计算量下降了 0.1 G, $mAP@0.5$ 提升了 1.7%; 模型 2 通过引入 LFDPN 结构, 实现多尺度特征的融合与多层次特征图的交互处理, 使模型在应对不同尺度目标时具备更强的适应性与表达能力, $mAP@0.5$ 提升了 1.5%; 模型 3 在模型 1 的基础上添加 Detect_LSCD 检测头, 使用共享卷积, 在减少模型参数量和计算量的基础上提高精度, $mAP@0.5$ 提升了 1.8%, 参数量下降了 0.65 M, 计算量




Fig. 11 Label distribution

图 11 标签分布情况

3.3 评价指标

为验证改进网络在仓储目标检测中的性能与表现, 本文使用的评估指标为准确率 (Precision, P)、召回率 (Recall, R)、类平均精度 (Average Precision, AP)、模型参数量 (Params)、IoU 阈值为 0.5 平均精度均值 (mean Average Precision at IoU threshold of 0.5, $mAP@0.5$)、计算量 (GFLOPs) 及每秒检测帧数 (Frame Per Second, FPS)^[19]。其中, 准确率 (Precision, P) 和召回率 (Recall, R) 的计算公式如式 (1)、式 (2) 所示。

$$P = \frac{TP}{FP + TP} \quad (1)$$

$$R = \frac{TP}{FN + TP} \quad (2)$$

其中, TP 指被模型预测为正类, 实际情况也是正类的样本数量; FP 为被模型预测为正类, 但实际情况为负类的样本数量; FN 表示预测为负类, 但实际为正类的样本数量。

AP 表示精度—召回曲线下的面积, 它实质上反映了从 0 到 1 的所有召回值的平均精度, 计算公式如式 (3)

下降了 1.6 G;模型 4 在模型 2 的基础上引入 DWR 结构进行改进,更高效地获取多尺度的上下文信息,减少特征提取的复杂过程,相较于单一模块配置,mAP@0.5 显著提升了 2.5%;模型 5 在模型 4 的基础上增加 Detect_LSCD 检测头,尽管 FPS 略有下降,但计算效率提升,相较于原模型,参数量下降了 0.72 M,计算量下降了 0.9 G,mAP@0.5 提升了 1.3%。综合评估可知,改进后的模型在保持较小帧率损失的基础上,提升了训练速度和检测精度。

Table 3 Impact of different modules on YOLOv8n performance

表 3 不同模块对 YOLOv8n 性能的影响

DWR	LFDPN	LSCD	mAP@0.5/%	Precision/%	Recall/%	GFLOPs /G	Params /M	FPS/f·s ⁻¹
×	×	×	64.8	71.3	58.8	8.1	3.01	372.1
√	×	×	66.5	75.7	56.8	8.0	2.95	364.8
×	√	×	66.3	73.2	57.4	9.4	3.04	242.4
√	×	√	66.6	73.1	60.1	6.5	2.36	422.8
×	√	√	67.3	73.5	59.9	9.2	2.98	224.3
√	√	√	66.1	72.5	60.3	7.2	2.29	234.5

3.4.2 算法对比实验

本文聚焦于更契合实际应用场景、对硬件条件要求较低且具有良好通用性的仓储环境目标检测算法。因此,模型的选择范围仅限于实时目标检测算法。这类模型易于部署,已在自动驾驶、仓储智能化等多个领域广泛应用。这些模型的选择不仅基于其在实时性和轻量化方面的突出表现,还考虑了其在目标检测领域的技术代表性。因此,选择 YOLOv3-tiny、YOLOv5n、YOLOv8s、YOLOv10n、YOLOv5-CE 作对比实验。YOLOv3-tiny 和 YOLOv5n 是 YOLO 系列中的经典轻量化版本,广泛应用于目标检测任务;YOLOv10n 则是近年来在轻量化和检测精度方面表现突出的改进模型,YOLOv5-CE 算法是近一年来仓储目标检测方向最新文献中的改进算法,通过自建数据集上复现其关键指标,并与 YOLOv8n-DFL 算法进行对比,所有对比模型均在相同的数据集上进行了性能验证。实验中的所有网络均从头开始训练,未使用官方预训练权重。本文比较了不同模型的 mAP@0.5、浮点运算量、参数量和帧率数据。通常而言,上述指标可以反映模型之间在准确性和复杂性上的差异。

表 4 列出了所提 YOLOv8n-DFL 与其他 6 个比较算法的实验结果。可以看出,YOLOv8n-DFL 算法优于其他模型。与 YOLOv8s 相比,YOLOv8n-DFL 在参数量仅为 YOLOv8s 的 1/5 时,mAP@0.5 达到了 66.1%,展现了更高的效率。与此同时,与同类型的轻量级模型 YOLOv3-tiny 和 YOLOv5n 相比,YOLOv8n-DFL 的参数量远小于上述模型,仅为 2.29 M,比这两者分别低出 9.94 M、0.58 M,且整体平均精度 mAP@0.5 高于 YOLOv3-tiny 和 YOLOv5n,分别提升了 9.2% 和 6.4%。这表明,所提策略可以大幅提升原始模型的综合性能。YOLOv8s 拥有更高的平均精度和准确率,但同时其计算量和模型参数量比 YOLOv8n-DFL 分别增加

了 2.9 倍、3.8 倍。由于 YOLOv8s 具有更高的网络深度与通道宽度,故在高层语义融合与上下文建模方面占优。在相同训练预算下,更大容量通常带来更高的上限表现。因此,在不设算力与体积约束的前提下,YOLOv8s 获得略高精度在预期之内。本文关注轻量化与部署可行性:YOLOv8n-DFL 在显著降低参数与 FLOPs 的同时,相比 YOLOv8n 实现了稳定的 mAP 和 Recall 提升,并在 GFLOPs、MParam 与端侧时延等效效率指标上更具优势,满足仓储机器人实时检测的工程约束。

同样,与先进的轻量级模型 YOLOv10n 相比,所提 YOLOv8n-DFL 在计算量和 mAP@0.5 上也取得了更好的结果。改进后的模型计算量比 YOLOv10n 低 2.2 G,mAP@0.5 优于 YOLOv10n,提升了 1.2%。与最新文献所提算法 YOLOv5-CE 相比,YOLOv8n-DFL 在 mAP@0.5、准确率指标上小幅领先,但在参数量和每秒检测帧率上远优于 YOLOv5-CE 算法,这主要得益于本文算法的轻量化与实时性改进。

从检测速度上看,参数量较大的算法 YOLOv3-tiny 处理速度较慢,而改进后的算法保持了较高的检测速度,且检测效果更佳。综上所述,所提的 YOLOv8n-DFL 在仓储环境多目标检测任务中表现出高检测精度、强泛化能力和鲁棒性。同时,YOLOv8n-DFL 模型由于具备更小的参数规模和较高的推理效率,更易于在嵌入式设备中部署,便于在工业仓储检测以及便携式智能终端等对实时性和资源占用要求较高的应用场景中发挥作用。未来研究将进一步探索在保持检测精度的前提下,持续减少模型参数量和计算开销,从而进一步提高推理速度,增强模型在资源受限环境中的实用性和普适性。

Table 4 Comparison of experimental results of different models

表 4 不同模型对比实验结果

算法	mAP@0.5 /%	Precision /%	Recall /%	GFLOPs /G	Params /M	FPS/f·s ⁻¹
YOLOv3-tiny	56.9	65.4	53.1	19.2	12.23	118
YOLOv5n	59.7	67.0	55.9	8.9	2.87	317
YOLOv8n	64.8	71.3	58.8	8.1	3.01	372.1
YOLOv8s	67.0	73.0	59.8	28.4	11.1	217.0
YOLOv10n	64.9	71.6	60.4	9.4	2.89	313
YOLOv5-CE ^[2]	64.8	72.1	59.8	8.5	34.3	76.7
YOLOv8n-DFL	66.1	72.5	60.3	7.2	2.29	234.5

3.4.3 检测结果可视化

为了直观评估改进后的算法在仓储目标检测中的优势,本文随机选取了 5 张图片进行可视化对照试验。YOLOv8n(左列)与 YOLOv8n-DFL(右列)的检测效果比较如图 12 所示(从上至下分别为第一至第五组)。

可以看出,第一组、第二组和第三组图片中,YOLOv8n 算法对叉车和托盘存在漏检情况,而改进后的算法较好地减少了漏检情况,并且提升了检测精度。从第四和第五组图片可以看出,改进后的模型在密集场景下提升了检测精度,但并没有出现错检和漏检情况,表明其具有一定的鲁



Fig. 12 Comparison of detection results
图 12 检测效果比较

棒性和稳定性。因此,本文YOLOv8n-DFL模型能够有效提高检测精度,且在复杂仓储环境下,仍能保持较高的检测水平,具有一定的实践应用潜力。

4 结语

随着智慧物流与仓储自动化需求的持续增长,仓储场景对高精度、低时延、低算力的目标检测提出了更高要求。主流目标检测算法在目标密集、尺度差异大、背景复杂的仓库环境中易出现漏检与误检情况,且难以兼顾模型体量与实时性。因此,对仓储多目标检测算法进行研究尤为重要。本文主要在现有仓储目标检测算法研究的基础上,提出一种基于YOLOv8的仓储多目标检测方法。在YOLOv8主干网络中使用DWR模块替换Bottleneck,通过扩张卷积、多尺度并行和残差加权在几乎不增加参数量的前提下,显著增强层内的多尺度上下文建模与有效感受野。之后构建LFDPN结构,通过双向扩散和特征聚焦显著加强跨尺度信息交互与小目标表征。此外,将YOLOv8原始检测头替换为LSCD轻量化检测头,在几乎不降低精度的前提下显著压缩检测头开销、提升收敛与跨尺度一致性。实验结果显示,与基线模型相比,YOLOv8-DFL大幅减少了模型参数量和计算量,模型参数量仅2.29 M,减少了23.92%;计算量仅为7.2 G,减少了11.11%;平均精度mAP@0.5从64.8%提升到66.1%,提升了1.3%。本文算法为实时性要求较高的检测场景提供了新的方法和轻量化的思路。

未来研究中,将进一步增加数据集数量,增强数据集多样性,并与更多其他先进算法作对比分析。同时,将经过优化的模型应用于资源受限的嵌入式检测平台,以实现更广泛的应用部署。此外,将致力于提升仓储目标检测数据集中小目标检测精度,并在实际应用中对所提算法作进一步完善。

参考文献:

[1] WANG J L. Steady improvement in logistics industry development efficiency[N]. People's Daliy Overseas Edition, 2025-02-18(003).
王俊岭. 物流业发展效能稳步提升[N]. 人民日报海外版, 2025-02-18(003).

[2] LIU T X, WANG F, LIU X, et al. Research on warehouse object detection based on improved YOLOv5 [J]. Electronic Measurement Technology, 2024, 47(14): 149-158.
刘庭浔, 王飞, 刘旭, 等. 基于改进YOLOv5的仓储物体检测研究[J]. 电子测量技术, 2024, 47(14): 149-158.

[3] HUANG J, FU M, TANG T, et al. Overview of target detection algorithm based on deep learning [C]//2024 IEEE 2nd International Conference on Sensors, Electronics and Computer Engineering (ICSECE), 2024: 1174-1178.

[4] CHEN H X, CHEN Z A, NING X, et al. Improved YOLOv10n dense pedestrian small target detection method [J]. Journal of Chinese Computer Systems, 2025-09-19. <https://link.cnki.net/urlid/21.1106.tp.20250618.1645.002>.
陈海秀, 陈子昂, 宁馨, 等. 改进YOLOv10n的密集行人小目标检测方

- 法[J/OL]. 小型微型计算机系统, 2025-09-19. <https://link.cnki.net/urlid/21.1106.tp.20250618.1645.002>.
- [5] CHEN L J, WANG F, WANG L, et al. Research on warehouse object detection algorithm based on SSD[J]. Software Guide, 2019, 18(4): 28-31.
陈亮杰, 王飞, 王梨, 等. 基于SSD的仓储物体检测算法研究[J]. 软件导刊, 2019, 18(4): 28-31.
- [6] WANG C, YUAN Q N, BAI H, et al. Lightweight object detection algorithm for warehouse goods[J]. Laser & Optoelectronics Progress, 2022, 59(24): 74-80.
王晨, 袁庆亮, 白欢, 等. 面向仓储货物的轻量化目标检测算法[J]. 激光与光电子学进展, 2022, 59(24): 74-80.
- [7] LIU H, LIU X, LI X L, et al. Improved lightweight PCB defect detection algorithm for YOLOv8n[J]. Electronic Measurement Technology, 2025, 48(13): 111-119.
刘辉, 刘旭, 李校林, 等. 改进YOLOv8n的轻量化PCB缺陷检测算法[J]. 电子测量技术, 2025, 48(13): 111-119.
- [8] JIANG K, SUN R Y, LI Z L, et al. Research on lightweight vehicle object detection algorithm by improved YOLOv8[J]. Journal of Chongqing University of Technology(Natural Science), 2025, 39(7): 35-42.
蒋康, 孙仁云, 李卓霖, 等. 改进YOLOv8的轻量化车辆目标检测算法研究[J]. 重庆理工大学学报(自然科学), 2025, 39(7): 35-42.
- [9] LI X, GENG S. Improved traffic sign detection algorithm for yolov5s[C]//2023 4th International Conference on Computer Engineering and Application (ICCEA), 2023: 696-699.
- [10] REN S, HE K, 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, 2016, 39(6): 1137-1149.
- [11] QIN L M, ZHANG Y Q, CUI H Y, et al. Traffic sign recognition method based on improved YOLOv8s[J]. Modern Electronic Technique, 2025, 48(17): 145-152.
秦伦明, 张云起, 崔昊杨, 等. 基于改进YOLOv8s的交通标志识别方法[J]. 现代电子技术, 2025, 48(17): 145-152.
- [12] ZHOU S J, WANG Y H, SHEN S C, et al. Research on object recognition in warehouse environment based on improved Faster R-CNN[J]. Computing Technology and Automation, 2024, 43(2): 187-191.
周诗捷, 王玉槐, 沈思橙, 等. 基于改进型Faster R-CNN的仓储环境物体识别技术研究[J]. 计算技术与自动化, 2024, 43(2): 187-191.
- [13] LI Y S, YANG A Y, LIU X, et al. Storage box detection method based on transformer improved Faster-RCNN[J]. Automation & Instrumentation, 2022(8): 1-6.
李映松, 杨爱英, 刘轩, 等. 基于Transformer改进的Faster-RCNN仓储箱体检测算法[J]. 自动化与仪器仪表, 2022(8): 1-6.
- [14] JIN Q, LI T J. Object recognition method based on deep learning in storage environment[J]. Journal of Beijing Information Science & Technology University(Science and Technology Edition), 2018, 33(1): 60-65.
金秋, 李天剑. 仓储环境下基于深度学习的物体识别方法研究[J]. 北京信息科技大学学报(自然科学版), 2018, 33(1): 60-65.
- [15] ZACCARIA M, MONICA R, ALEOTTI J. A Comparison of deep learning models for pallet detection in industrial warehouses[C]//16th International Conference on Intelligent Computing and Communications Processing (ICCP), 2020: 417-422.
- [16] RUTINOWSKI J, YOUSSEF H, GOUDA A, et al. The potential of deep learning based computervision in warehousing logistics[J]. Logistics Journal: Proceedings, 2022(18): 1-10.
- [17] ZHANG J X, FANG D. Detection of missing shockproof hammers based on YOLOv8-SPH[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 251-261.
张吉祥, 方东. 基于YOLOv8-SPH的防震锤缺失检测[J]. 电子测量与仪器学报, 2025, 39(2): 251-261.
- [18] BAI H. Research on grasp target detection oriented of warehouse automation[D]. Guiyang: Guizhou University, 2022.
白欢. 面向仓储自动化的抓取目标检测研究[D]. 贵阳: 贵州大学, 2022.
- [19] DU C, WANG X, DONG Z S, et al. Improved YOLOv5s flame and smoke detection method for underground garage[J]. Computer Engineering and Applications, 2024, 60(11): 298-308.
杜辰, 王兴, 董增寿, 等. 改进YOLOv5s的地下车库火焰烟雾检测方法[J]. 计算机工程与应用, 2024, 60(11): 298-308.

(责任编辑: 孙 娟)