

DOI:10.19651/j.cnki.emt.2519050

# 基于 DOLN-YOLO 的复杂环境下的条码检测算法<sup>\*</sup>

何奥辉 张丰收 庄高帅 段庆阳 冯宝阳

(河南科技大学机电工程学院 洛阳 471003)

**摘要:** 针对现有目标检测模型在复杂环境下检测条形码时易受干扰导致精度不足,以及模型复杂度高难以部署于移动端低算力设备的问题,本研究提出了一种基于 YOLOv8 的轻量级高精度检测算法 DOLN-YOLO。首先,引入以 DWConv 重构的 DW-HGNetV2 作为主干网络,在增强多尺度特征提取能力的同时显著降低计算复杂度;其次,构建 OD-C3Ghost 模块替换 C2f 模块,增强了对条码复杂形变的动态感知能力,并进一步消除计算冗余;然后,设计了轻量级共享细节增强检测头 LSDEDH,利用 DEConv 的梯度-强度双路协同机制提升模型的特征泛化能力,并采用异构卷积共享策略降低资源损耗;最后,提出了复合损失函数 NWD-PIoUV2,联合归一化 Wasserstein 距离与动态聚焦 PIoUV2 损失,缓解微小定位偏差的优化难题并加快收敛速度。实验结果表明,相比于基准模型,DOLN-YOLO 的 mAP@0.5 提升了 0.92%,mAP@0.5:0.95 提升了 4.57%,同时参数量和计算量分别降低了 58.8%和 48.6%,证明了算法在检测复杂环境下的条码的优越性。DOLN-YOLO 为物流、医疗、零售等场景提供了兼具高鲁棒检测能力与高效移动部署的解决方案。

**关键词:** 深度学习;目标检测;条形码;YOLOv8

**中图分类号:** TP391.7;TN98 **文献标识码:** A **国家标准学科分类代码:** 520.6040

## Barcode detection algorithm based on DOLN-YOLO in complex environments

He Aohui Zhang Fengshou Zhuang Gaoshuai Duan Qingyang Feng Baoyang

(School of Mechanical Engineering, Henan University of Science and Technology, Luoyang 471003, China)

**Abstract:** To address the issues of existing object detection models being prone to interference and resulting in insufficient accuracy when detecting barcodes in complex environments, as well as the high model complexity making deployment on low-computing-power mobile devices challenging, this study proposes a lightweight, high-precision detection algorithm called DOLN-YOLO based on YOLOv8. First, the DW-HGNetV2 architecture, reconstructed using deeply separable convolutions, is introduced as the backbone network, which enhances multi-scale feature extraction capabilities while significantly reducing computational complexity. Second, the OD-C3Ghost module is constructed to replace the C2f module, enhancing dynamic perception capabilities for complex barcode deformations and further eliminating computational redundancy. Third, a lightweight shared detail enhancement detection head is designed, utilizing the gradient-strength dual-channel coordination mechanism of DEConv to enhance the model's feature generalization capabilities, and adopts a heterogeneous convolution sharing strategy to reduce resource consumption; finally, a composite loss function NWD-PIoUV2 is proposed, combining normalized Wasserstein distance with dynamic focus PIoUV2 loss, to mitigate the optimization challenge of minor localization deviations and accelerate convergence speed. Experimental results demonstrate that, compared to the baseline model, DOLN-YOLO achieves a 0.92% improvement in mAP@0.5 and a 4.57% increase in mAP@0.5:0.95, while reducing parameters and computational costs by 58.8% and 48.6% respectively. This validates the algorithm's superiority in detecting barcodes under complex environments. DOLN-YOLO provides a solution featuring both robust detection capability and efficient mobile deployment for logistics, healthcare, retail, and other application scenarios.

**Keywords:** deep learning; object detection; barcode; YOLOv8

## 0 引言

自 20 世纪 70 年代商业化以来,条形码技术已成为全

球货物运输、物流管理和工业自动化的核心基础设施。快件和大多数产品包装上都标有一维条形码,以便在运输、管理、存储和跟踪的整个过程中检索其信息<sup>[1]</sup>。然而,随着条

收稿日期:2025-06-08

\* 基金项目:国家重点基础研究发展计划(J2019-VII-0017-0159)项目资助

形码使用次数的增长和应用场景的复杂化,对条形码检测算法提出了更高的要求。传统算法容易受外部因素影响(如脏污、破损和遮挡等)而降低检测精度,计算复杂度高,且难以嵌入低功耗设备,阻碍了实际应用。因此,采用更高效、更准确的条形码检测算法至关重要。

近年来,深度学习技术的突破性进展推动了目标检测领域的范式革新。两阶段算法通过区域建议网络(RPN)生成候选框然后进行精细检测,虽具有较高定位精度,但其多级流水线结构导致计算复杂度高、推理速度慢。流行的两阶段算法有R-CNN系列<sup>[2]</sup>和R-FCN<sup>[3]</sup>等。相较之下,单阶段算法通过端到端的特征回归直接预测目标边界框与类别,在检测速度与计算效率上具有显著优势。以YOLO系列算法<sup>[4]</sup>和SSD<sup>[5]</sup>等为代表的单阶段模型凭借其轻量化架构与并行计算的特性,在嵌入式设备与实时系统中得到广泛应用。

目前,利用深度卷积神经网络进行条形码检测的研究已取得显著进展。Zhang等<sup>[6]</sup>提出一种基于区域的端到端网络,能够在复杂环境中精确定位和分类条形码。Kolekar等<sup>[7]</sup>采用角度预测网络校正条形码旋转,并结合SSD模型完成检测。Xu等<sup>[8]</sup>尝试融合YOLOv4与多源信息进行复杂环境下的条形码检测,但效果一般。周为鹏等<sup>[9]</sup>利用YOLOv5定位条形码然后校正失真图像进行识别,然而检测精度仍有提升空间。Li等<sup>[10]</sup>提出了一种级联深度卷积神经网络检测一维条形码的策略,获得了更高的检测率和鲁棒性,但也增加了推理时间。王正家等<sup>[11]</sup>通过改进YOLOv7-tiny骨干网络并引入CBAM轻量级注意力机制,在条码检测精度上取得了一定提升。黄勇等<sup>[12]</sup>采用多尺度分层特征图自适应加权融合方法改进YOLOv8,提高了检测精度,但未能减少模型参数量。

此外,其他目标检测领域的研究在应对模型轻量化、小目标检测及复杂环境鲁棒性等共性挑战方面也取得了积极成果。朱圣博等<sup>[13]</sup>通过引入动态检测头并平衡深浅层特征权重,有效实现了YOLOv8在小型船舶检测上的轻量化与高精度平衡。Miao等<sup>[14]</sup>将感受野注意力卷积与散射特征增强模块融入YOLOv8,提升了智能工厂车辆检测的精度和速度。陈俊生等<sup>[15]</sup>提出的MFES-YOLOv8n模型结合增强型SimAM注意力机制与特征增强策略,显著提高了光伏电池缺陷检测精度。

尽管上述研究为条形码检测提供了有价值的贡献和改进思路,但在模型精度、轻量化水平,特别是针对复杂环境下条形码检测的鲁棒性方面,仍有较大优化空间。

YOLO系列算法作为经典的单阶段目标检测框架,凭借其在精度和速度上的显著优势,成为条形码实时检测的理想选择。其中,YOLOv8在网络架构设计、样本分配策略及损失函数优化等方面进行了重要改进。该系列包含n、s、m、l、x五种型号,其网络深度和通道数依次递增。综合考虑条形码检测对实时性与准确性的双重需求,本研究

选择以在精度与速度间取得较佳平衡的YOLOv8s作为基准模型进行优化,旨在进一步提升检测效率,并为在嵌入式或移动端等资源受限环境下的高效部署奠定基础。

## 1 算法改进

YOLOv8在条形码检测任务中存在骨干网络计算复杂度高、对高频特征建模针对性不足等问题,造成计算资源浪费;其C2f模块采用的静态卷积机制难以适应条形码目标在自然场景中的多尺度分布、形态畸变和纹理退化;此外,其检测头存在参数冗余与多尺度特征适应性不足的缺陷。最后,其损失函数存在微小位置偏差敏感等问题。

针对骨干网络的不足,本研究采用深度可分离卷积(DWConv)重构HGNetV2主干得到DW-HGNetV2取代原主干,在保留并增强多尺度特征提取能力的同时,显著降低了计算复杂度。针对C2f模块的静态卷积局限,本研究设计了OD-C3Ghost模块进行替代,该模块融合了全维度动态卷积(ODConv)的动态感知机制与GhostConv的轻量化特性,在有效降低模型复杂度的同时,显著增强了对条形码多尺度、形态畸变和纹理退化等复杂特征的建模与适应能力。针对检测头的缺陷,本研究基于特征解耦理论与轻量化原理,提出了轻量级共享细节增强卷积检测头LSDEDH,通过组归一化(GN)策略创新、细节增强卷积(DeConv)算子重构及梯度-强度双流特征融合的参数共享机制进行三重协同优化,强化了遮挡与模糊场景下的条形码信息重组能力,提升了精度与效率。最后,针对微小位置偏差的梯度敏感性问题,本研究提出了NWD-PIoUV2复合损失函数,联合归一化Wasserstein距离(NWD)与动态聚焦PIoUV2损失以缓解梯度突变。本研究提出的DOLN-YOLO模型的整体网络结构如图1所示。

### 1.1 轻量级DW-HGNetV2网络

YOLOv8作为当前主流实时检测框架,其主干网络CSPDarknet虽在通用目标检测中表现优异,但在复杂环境下的条形码检测任务中存在诸如存在计算冗余、细粒度特征捕获不足等问题,故本研究提出更加轻量化的DW-HGNetV2网络代替原主干网络以弥补相关缺陷。

HGNetV2<sup>[16]</sup>作为百度嵌入RT-DETR框架的新型轻量级高效骨干网络,其核心优势在于分层式架构设计,显著提升了模型在复杂图像场景下的多尺度特征提取能力。其网络架构如图2所示。

HGNetV2的分层架构通过渐进式特征提取维持了低层级空间信息流,可以避免条形码早期细节湮灭。HG块作为该网络的核心组件,通过层级化处理机制,实现了对低层级空间细节与高层级语义特征的有效协同捕获,其详细结构如图3所示。

然而,HG模块依赖的标准卷积操作(Conv)在实时条形码检测任务中会引入冗余计算成本。针对此缺陷,本研究提出轻量化改进方案Light\_HGBlock,其核心在于通过

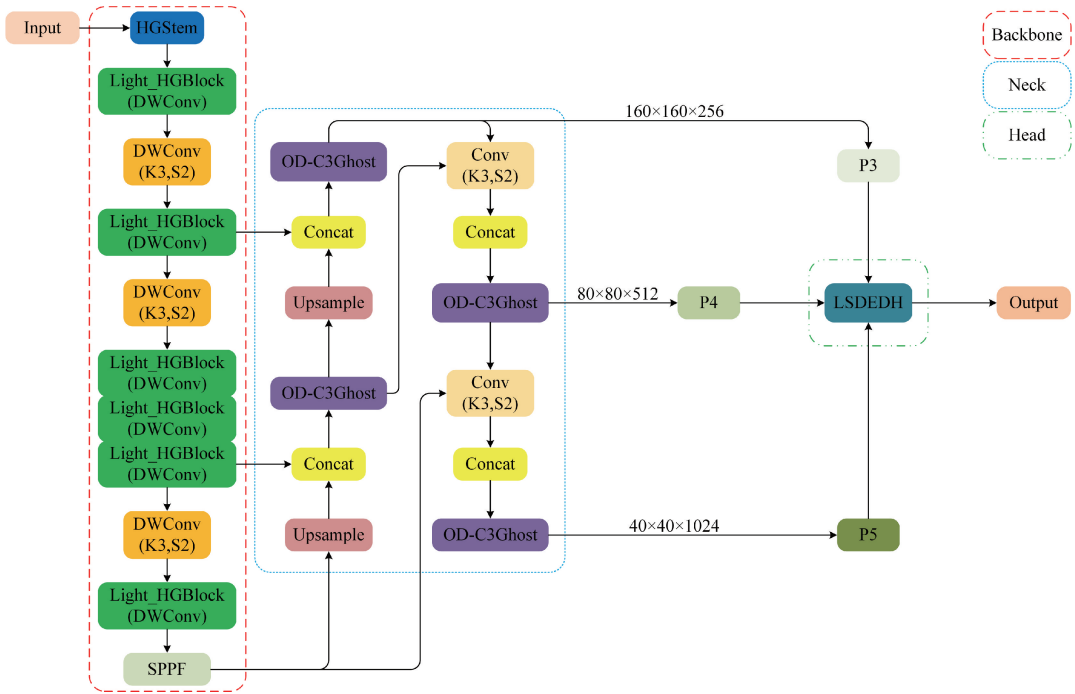


图 1 DOLN-YOLO 网络结构  
Fig.1 DOLN-YOLO network structure

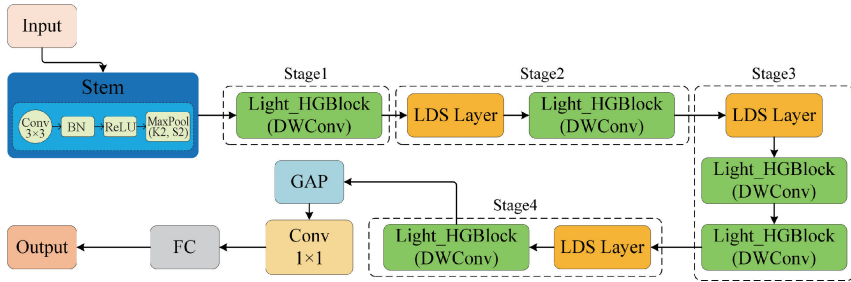


图 2 HGNetV2 网络结构  
Fig.2 HGNetV2 network structure




图 3 HGBlock 细节示意图  
Fig.3 HGBlock detail diagram

核实现跨通道特征融合与维度变换,建立抗干扰地多尺度语义关联。这种结构上的重构可以在显著降低模型参数数量和计算复杂度的同时,最大限度地维持网络的关键特征表征能力。DWConv 原理图如图 4 所示。




图 4 DWConv 原理图  
Fig.4 DWConv schematic diagram

DWConv 策略性地替代 Conv 层。DWConv 通过解耦空间相关性与通道相关性学习过程,将传统卷积分解为两个独立操作:深度卷积(Depthwise Convolution)独立作用于每个输入通道,执行轻量化的空间特征提取,有效保留条形码图像关键的局部方向性纹理和边缘信息;逐点卷积(Pointwise Convolution)紧随 DW 层之后,通过  $1 \times 1$  卷积

以数学公式表达 DWConv 的轻量化优势,记输入特征图的高、宽和输入通道数分别为  $H$ 、 $W$  和  $C_I$ , 卷积核的高和宽都为  $k$ , 输出通道数为  $C_O$ 。

$$P = C_I \cdot C_O \cdot k \cdot k \quad (1)$$

$$F = C_I \cdot C_O \cdot H \cdot W \cdot k \cdot k \quad (2)$$

$$P_D = C_I \cdot k \cdot k + C_I \cdot C_O \quad (3)$$

$$F_D = C_I \cdot H \cdot W \cdot k \cdot k + C_I \cdot C_O \cdot H \cdot W \quad (4)$$

其中,  $P$  和  $F$  分别为普通卷积参数量和和计算量,  $P_D$  和  $F_D$  分别为 DWConv 参数量和和计算量。推导得:

$$\frac{P_D}{P} = \frac{F_D}{F} = \frac{1}{C_O} + \frac{1}{k^2} \quad (5)$$

由上式可知,使用 DWConv 使模型参数量和计算量明显下降。

## 1.2 融合全维度动态卷积的 OD-C3Ghost 模块

尽管 YOLOv8 的 C2f 模块通过跨阶段梯度流设计提升了特征融合能力,但其静态卷积核在面对物流场景中条形码的几何形变时缺乏空间位置敏感性,且在运动模糊、低照度等退化场景下易丢失高频纹理细节导致对复杂场景下条形码的表征能力不足。为此,本文创新性地采用融合了 ODConv<sup>[17]</sup> 的 C3Ghost 模块对 C2f 模块进行结构重构,构建具有多维动态感知能力的 OD-C3Ghost 模块。

C3Ghost 模块保留了 C3 模块的多分支、分层处理信息的整体框架和优势,将其内部的原 Bottleneck 模块更换为更加轻量化的 GhostBottleneck 模块<sup>[18]</sup>。GhostBottleneck 模块中的 GhostConv 通过廉价的线性运算高效生成更多的特征图,显著降低了模型所需的计算参数,有效避免了资源浪费。

数学上,假定输入数据的尺寸为  $h \times w \times c$ , 输出数据的尺寸为  $h' \times w' \times n$ , 卷积核尺寸为  $k \times k$ , 线性运算核大小为  $d \times d$ , 通过线性运算  $\varphi_i$  操作后得到的特征图为  $s$  个, 则 GhostConv 卷积与标准卷积的理论加速比( $r_s$ )和参数压缩比( $r_c$ )分别为:

$$r_s = \frac{n \cdot h' \cdot w' \cdot c \cdot k \cdot k}{\frac{n}{s} \cdot h' \cdot w' \cdot c \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot h' \cdot w' \cdot d \cdot d} = \frac{c \cdot k \cdot k}{\frac{1}{s} \cdot c \cdot k \cdot k + \frac{s-1}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx s \quad (6)$$

$$r_c = \frac{n \cdot c \cdot k \cdot k \cdot k}{\frac{n}{s} \cdot c \cdot k \cdot k \cdot k + (s-1) \cdot \frac{n}{s} \cdot d \cdot d} \approx \frac{s \cdot c}{s+c-1} \approx \frac{s \cdot c}{c} = s \quad (7)$$

由此可知,GhostConv 相较于标准卷积参数量和计算量都有明显降低,约为后者的  $\frac{1}{s}$ 。

但 GhostConv 核心的初始特征生成步骤仍依赖于静态的标准卷积,这种固定的卷积核在处理条形码这类在复杂场景中易受尺度、方向、遮挡和光照等因素影响的细长目标时,特征提取的适应性和灵活性存在局限,故本研究引入 ODConv 嵌入到 GhostBottleneck 模块中。由于第

1 个 GhostConv 模块负责关键的通道扩展和初始特征表达增强,所以选择第 1 个 GhostConv 模块内的标准卷积操作替换为 ODConv,这样不仅可以保持模块的轻量化优势,还能生成更具判别力和鲁棒性的初始特征图,为后续运算提供更高质量的输入基础。改进后的 OD-C3Ghost 模块结构如图 5 所示。

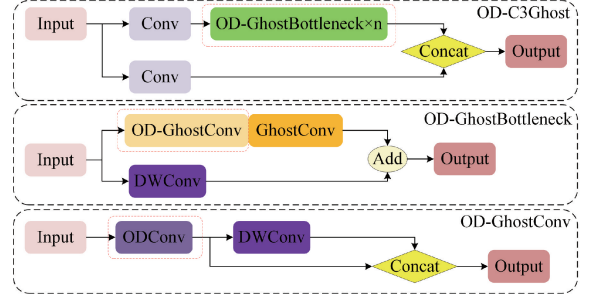


图 5 OD-C3Ghost 结构

Fig. 5 OD-C3Ghost structural

ODConv 作为一种新型的动态卷积技术,引入了多维注意力机制,通过卷积核的空间尺寸、输入通道数、输出通道数和卷积核的大小形状 4 个维度的协同机制,实现了卷积算子的全维度动态优化。其中,并行式多维注意力架构通过独立的全连接层组同步生成各维度注意力权重,在保证跨维度信息融合的同时,利用核共享策略降低了计算冗余。ODConv 结构如图 6 所示。

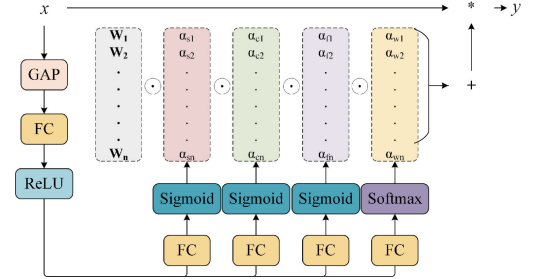


图 6 全维度动态卷积结构

Fig. 6 ODConv structure

从结构图中可知,输入特征  $x$  经过了通道级全局平均池化(GAP)、全连接层(FC)和修正线性单元(ReLU)后生成了 4 个维度的注意力值,然后通过 Softmax 函数和 Sigmoid 函数进行归一化处理以生成注意力标量。

ODConv 动态卷积操作可以表示为:

$$y = \left( \alpha_{w1} \odot \alpha_{f1} \odot \alpha_{c1} \odot \alpha_{s1} \odot W_1 + \dots \right) * x \quad (8)$$

其中,  $x$  和  $y$  表示输入和输出特征,  $x \in \mathbf{R}^{h \times w \times c_{in}}$ ,  $y \in \mathbf{R}^{h \times w \times c_{out}}$ ;  $W_i$  为第  $i$  个卷积核;  $\alpha_{wi}$  表示卷积核  $W_i$  的注意力标量;  $*$  为卷积运算;  $\odot$  表示在卷积核空间不同维度上的乘法运算;  $\alpha_{si}$ ,  $\alpha_{ci}$  和  $\alpha_{fi}$  分别表示沿卷积核空间的空间维度、输入通道维度和输出通道维度上新引入的 3 个注意

力标量。

### 1.3 基于共享细节增强卷积的 LSDEDH 检测头

在基于 YOLOv8 的条形码检测任务中,原有的检测头由于结构设计的限制,存在参数冗余、难以有效解耦多尺度特征等性能瓶颈。为此,本研究提出了轻量级共享细节增强检测头 LSDEDH,通过三重协同优化机制对其进行优化,其结构如图 7 所示。




图 7 LSDEDH 检测头  
Fig. 7 LSDEDH detection head

首先,基于特征通道解耦理论,引入 GN 来替代传统的批归一化(BN)。与 BN 对批次统计量的强依赖性相比,GN 通过子组内特征自归一化机制,有效缓解了小批量训练过程中统计量的时间偏差问题<sup>[19]</sup>。

GN 的归一化过程可表示如下。假设输入的四维张量  $(N, C, H, W)$ ,  $N$  代表批量大小,  $C$  为通道数,  $H$  和  $W$  代表输入的高度和宽度。将通道数分为  $G$  组,则每组包含  $\frac{C}{G}$  个通道。对每个输入张量的每个组的每个位置数据  $(H$  和  $W)$  计算均值  $\mu_g$  和方差  $\sigma_g^2$  :

$$\mu_g = \frac{1}{\frac{C}{G} \cdot H \cdot W} \sum_{i=1}^{\frac{C}{G}} \sum_{h=1}^H \sum_{w=1}^W x_{g,i,h,w} \quad (9)$$

$$\sigma_g^2 = \frac{1}{\frac{C}{G} \cdot H \cdot W} \sum_{i=1}^{\frac{C}{G}} \sum_{h=1}^H \sum_{w=1}^W (x_{g,i,h,w} - \mu_g)^2 \quad (10)$$

对每个输入进行归一化得到的输出为:

$$\hat{x}_{g,i,h,w} = \frac{x_{g,i,h,w} - \mu_g}{\sqrt{\sigma_g^2 + \epsilon}} \quad (11)$$

式中:  $\epsilon$  为一个小常数,防止  $\sigma_g^2 + \epsilon = 0$ 。

通过可学习参数,对输出进行缩放和偏移:

$$y_{g,i,h,w} = \gamma_g \cdot \hat{x}_{g,i,h,w} + \beta_g \quad (12)$$

式中:  $\gamma_g$  和  $\beta_g$  是对每组的可学习参数。

其次,基于特征先验建模理论,LSDEDH 框架整合了 DEConv<sup>[20]</sup>。该模块通过结构重参数化技术,在推理阶段将多分支卷积操作等效融合为单一  $3 \times 3$  卷积核,实现了零计算开销的特征表示增强。DEConv 的结构如图 8 所示。

在此架构中,标准卷积从图像中提取全局强度级信息分布,中央差分卷积(CDC)、角度差分卷积(ADC)、水平差分卷积(HDC)与垂直差分卷积(VDC)构成的差分卷积组,

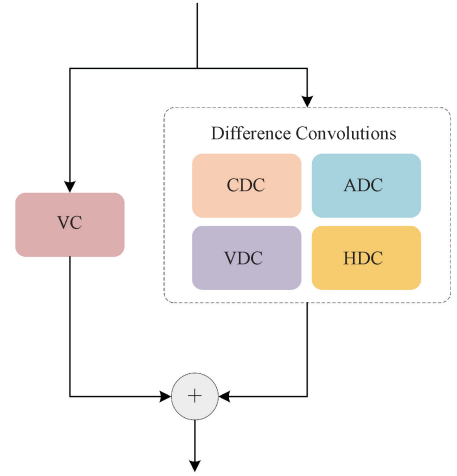


图 8 DEConv 结构  
Fig. 8 DEConv structure

通过方向性梯度算子强化边缘结构,并最终生成富含边缘结构信息的增强特征图。这种梯度-强度双流协同机制显著提升了模型对条形码局部方向性纹理的感知能力,尤其在低对比度、运动模糊等退化场景下展现出更强的特征泛化性。

各差分卷积的数学表征为:

$$y(p_o) = \sum_{p_n \in R} w(p_n) [x(p_o + p_n) - x(p_o)] \quad (13)$$

其中,  $R$  表示不同方向的领域,根据不同的差分卷积选取,如垂直差分卷积的  $R$  表示垂直方向的领域。

重参数化技术可表示为:

$$\mathbf{F}_{out} = DEConv(\mathbf{F}_{in}) = \sum_{i=1}^5 \mathbf{F}_{in} * \mathbf{K}_i =$$

$$\mathbf{F}_{in} * \left( \sum_{i=1}^5 \mathbf{K}_i \right) = \mathbf{F}_{in} * \mathbf{K}_{cut} \quad (14)$$

其中,  $DEConv(\cdot)$  表示 DEConv 运算;  $\mathbf{K}_i$  代表 VC, VDC, ADC, HDC 和 CDC 的核;  $*$  表示卷积操作;  $\mathbf{K}_{cut}$  为将并行卷积组合在一起的转换核。

LSDEDH 还采用了异构卷积共享策略来降低模块复杂度。在特征预处理阶段,独立的  $1 \times 1$  Conv\_GN 模块实现了多级特征维度对齐和分布正则化;在核心计算阶段,构建了双分支共享的  $3 \times 3$  DEConv 组,其输出分别连接到分类(Conv\_Cls)和回归(Conv\_Reg)子网络。该设计通过权重共享矩阵  $\mathbf{W}_{shared} \in \mathbf{R}^{C_{mid} \times C_{out}}$  实现了分类或回归任务的表示与参数重用的解耦,以减少参数数量。最后,还引入了可微尺度变换层以解决检测头层级之间的目标尺度差异问题。该模块通过可学习的参数矩阵对特征张量进行仿射变换以提高小目标的检测精度,同时保持大目标的定位精度。

### 1.4 复合损失函数优化策略

在目标检测任务中,边界框回归(BBR)扮演着至关重要的角色,且 BBR 的性能在很大程度上受到其损失函数的

影响,故不同的检测任务中选择不同的损失函数可以起到优化检测性能的效果。针对现有 IoU 系列损失函数在细粒度目标检测中存在的几何敏感性缺陷(如微小位置偏差引发梯度突变)以及锚框质量感知能力不足问题,本研究提出融合分布度量与动态聚焦机制的复合损失函数 NWD-PIoUV2。

PIoU<sup>[21]</sup>是一种高效的损失函数,它结合了目标大小的自适应惩罚因子和基于锚框质量的梯度调整函数,与目前基于 IoU 的损失函数相比,具有更快的收敛速度。

如图 9 和图 10 所示,基于 IoU 的损失函数如 CIoU 和 DIoU<sup>[22]</sup>等都采用如锚框和目标框的最小外接边框(虚线边框)的对角线长度或其面积等尺寸信息充当损失因子的分母,而 PIoU 损失则简单地采用目标框的边缘长度作为损失因子的分母,进行损失归一化。




图 9 CIoU 和 DIoU 计算示意图

Fig. 9 Schematic diagram of CIoU and DIoU calculations

CIoU 和 DIoU 的计算公式可表示为:

$$L_{\text{CIoU}} = L_{\text{IoU}} + \frac{d^2}{c^2} + \alpha * v, 0 \leq L_{\text{CIoU}} \ll 2 \quad (15)$$

$$\alpha = \frac{v}{1 - \text{IoU} + v} \quad (16)$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{w_{\text{gt}}}{h_{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (17)$$

$$L_{\text{DIoU}} = L_{\text{IoU}} + \frac{d^2}{c^2}, 0 \leq L_{\text{DIoU}} \ll 2 \quad (18)$$




图 10 PIoU 计算示意图

Fig. 10 PIoU calculation diagram

PIoU 的计算公式可表示为:

$$L_{\text{PIoU}} = L_{\text{IoU}} + 1 - e^{-p^2}, 0 \leq L_{\text{PIoU}} \ll 2 \quad (19)$$

$$p = \left( \frac{dw_1}{w_{\text{gt}}} + \frac{dw_2}{w_{\text{gt}}} + \frac{dh_1}{h_{\text{gt}}} + \frac{dh_2}{h_{\text{gt}}} \right) / 4 \quad (20)$$

在 PIoU 的基础上引入了一个由单一超参数控制的非单调注意层,以提高高质量锚框在其聚焦中的有效性,得到了新的损失函数 PIoUV2<sup>[23]</sup>。

引入注意力层的 PIoUV2 的注意函数和损失函数定义为:

$$q = e^{-p}, q \in (0, 1] \quad (21)$$

$$u(x) = 3x \cdot e^{-x^2} \quad (22)$$

$$L_{\text{PIoUV2}} = u(\lambda q) \cdot L_{\text{PIoU}} = 3(\lambda q) \cdot e^{-(\lambda q)^2} \cdot L_{\text{PIoU}} \quad (23)$$

NWD<sup>[24]</sup>是一种基于概率分布相似性的边界框相似度量方法,旨在解决传统 IoU 对微小位置偏差过度敏感的问题。其核心思想是通过将边界框建模为概率分布,并利用 Wasserstein 距离度量分布的相似性,从而更好地评估边界框的匹配程度。计算过程如下:

1) 构建 2D 高斯分布模型

令水平边界框  $A = (c_{xA}, c_{yA}, w_A, h_A)$ , 其中,  $(c_{xA}, c_{yA})$  代表中心坐标,  $(w_A, h_A)$  代表宽度和高度。当满足式(22)时,  $A$  可以建模为二维高斯分布  $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ :

$$(x - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (x - \boldsymbol{\mu}) = 1 \quad (24)$$

$$\boldsymbol{\mu} = \begin{bmatrix} c_{xA} \\ c_{yA} \end{bmatrix}, \boldsymbol{\Sigma} = \begin{bmatrix} \frac{w_A^2}{4} & 0 \\ 0 & \frac{h_A^2}{4} \end{bmatrix} \quad (25)$$

其中,  $x, \boldsymbol{\mu}$  和  $\boldsymbol{\Sigma}$  分别表示高斯分布的坐标  $(x, y)$ 、均值向量和协方差矩阵。

2) 归一化高斯 Wasserstein 距离

令水平边界框  $B = (c_{xB}, c_{yB}, w_B, h_B)$ , 其中,  $(c_{xB}, c_{yB})$  代表中心坐标,  $(w_B, h_B)$  代表宽度和高度。以最佳传输理论的 Wasserstein 距离来计算,则两个二维高斯分布  $N_A$  和  $N_B$  二阶 Wasserstein 距离定义可最终简化为:

$$W_2^2(N_A, N_B) = \left\| \left( \begin{bmatrix} c_{xA}, c_{yA}, \frac{w_A}{2}, \frac{h_A}{2} \end{bmatrix}^T, \begin{bmatrix} c_{xB}, c_{yB}, \frac{w_B}{2}, \frac{h_B}{2} \end{bmatrix}^T \right) \right\|_2^2 \quad (26)$$

进行指数形式归一化得到  $A$  和  $B$  的相似性度量:

$$\text{NWD}(N_A, N_B) = \exp\left(-\frac{\sqrt{W_2^2(N_A, N_B)}}{C}\right) \quad (27)$$

其中,  $C$  是与数据集有关的常数,可改变其大小以达到最佳性能。

NWD 度量计为损失函数的定义为:

$$L_{\text{NWD}} = 1 - \text{NWD}(N_A, N_B) \quad (28)$$

本研究将 PIoUV2 损失和 NWD 损失进行线性融合以实现优势互补,新的复合损失函数 NWD-PIoUV2 可表示为:

$$L_{\text{PIoUV2-NWD}} = 0.5L_{\text{PIoUV2}} + 0.5L_{\text{NWD}} \quad (29)$$

## 2 实验与分析

### 2.1 实验介绍

本节首先介绍了本研究中使用的自制条形码数据集,然后介绍了实验环境,最后介绍了评估模型有效性的相关评价指标。

#### 1) 数据集

为应对真实场景中条形码的多维度退化问题,本研究构建了复杂度较高的自制条形码检测数据集。数据采集过程严格遵循工业检测标准,结合线上开源资源抓取和线下多设备拍摄,涵盖了污垢、褶皱、眩光、遮挡、模糊和损坏等多种典型缺陷模式。为进一步模拟复杂环境干扰,通过混合增强策略对数据集图片进行随机旋转、改变曝光度、添加高斯噪声和模拟遮挡等操作。最终数据集包含 3 935 幅高分辨率图像,按 8 : 1 : 1 的比例分为训练集(3 147 幅)、验证集(394 幅)和测试集(394 幅)。图 11 显示了数据集中具有代表性的挑战样本,突出了它们在训练鲁棒检测模型中的价值。




图 11 自制数据集中的代表性图像

Fig. 11 Representative images from the self-made dataset

#### 2) 实验环境

本文实验在 Windows11 操作系统上进行,在 NVIDIA GeForce RTX 4060Ti 的基础上,配置实验环境 Python3. 11. 9、Pytorch2. 4. 1 和 CUDA12. 1。实验参数设置如表 1 所示。

表 1 实验参数

Table 1 Experimental parameters

参数	设置
图像大小	640×640
训练迭代周期	300
批次大小	32
线程	8
优化器	SGD
动量系数	0.937
初始学习率	0.01
权重衰减	0.000 5

#### 3) 评价指标

为了测试改进模型的检测性能,本文使用精度、召回率、mAP0. 5、mAP0. 5:0. 95、模型参数量(Parameters)、浮点运算量(GFLOPs)和模型大小(ModelSize)以及 FPS 作为评估指标<sup>[25]</sup>。P、R 和 mAP 的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (30)$$

$$R = \frac{TP}{TP + FN} \quad (31)$$

$$AP = \int_0^1 P(R) dR \quad (32)$$

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \quad (33)$$

其中,TP 代表预测正确的正样本数量,FP 表示预测为负例的负样本数量,FN 表示预测错误的正样本数量。mAP 指多种类别 AP 的均值,mAP@0. 5 表示 IoU 阈值是 0. 5 时全部目标类别的检测平均精度,mAP@0. 5:0. 95 表示从共计 10 个 IoU 阈值(0. 5~0. 95,步长 0. 05)上计算得到的平均检测精度。

### 2.2 消融实验

为了验证本研究中使用的 DW-HGNetV2(A)、OD-C3Ghost(B)、LSDEDH 检测头(C)模块和 NWD-PIoUV2(D)损失函数的优化效果,本节设计了 8 组消融实验。实验数据如表 2 所示。

表 2 消融实验结果

Table 2 Ablation experiment results

A	B	C	D	mAP@0. 5/%	mAP@0. 5:0. 95/%	P/%	R/%	Params/10 <sup>6</sup>	FLOPs/G	FPS/fps
—	—	—	—	98.49	79.83	96.32	97.14	11.13	28.40	<b>254.40</b>
✓	—	—	—	98.68	81.68	97.28	97.12	7.78	21.20	239.60
—	✓	—	—	98.72	81.95	96.89	97.60	7.06	18.30	231.50
—	—	✓	—	98.64	82.57	97.46	97.87	8.43	23.30	236.90
✓	✓	—	—	98.75	83.12	97.06	97.84	6.48 M	18.20	233.60
✓	—	✓	—	98.91	83.87	97.88	97.25	6.77 M	19.60	230.40
—	✓	✓	—	98.76	83.69	97.74	97.93	5.36 M	15.70	227.50
✓	✓	✓	—	99.30	83.80	98.00	97.75	4.58 M	14.60	225.60
✓	✓	✓	✓	<b>99.41</b>	<b>84.40</b>	<b>98.20</b>	<b>98.60</b>	<b>4.58 M</b>	<b>14.60</b>	221.30

实验数据表明：首先，各模块的独立改进均具有有效性。DW-HGNetV2通过DWConv重构HGNetV2的卷积范式，在保留多尺度特征提取能力的同时，将参数量压缩了30.1%，计算量降低了25.4%，mAP@0.5提升了0.19%，证明了对条形码纹理的高效编码能力；OD-C3Ghost结合ODConv的动态感知和GhostConv的轻量化优势，互补性消除计算冗余，即计算量锐减35.6%，参数量减少36.7%，且mAP@0.5提升了0.23%，体现了其对复杂形变的鲁棒性；LSDEDH检测头采用组归一化与DEConv，将mAP@0.5:0.95提升至82.57%，验证了梯度-强度双路特征融合有效增强了复杂样本判别力。其次，模块组合展现出显著的协同增益效应。DW-HGNetV2主干与OD-C3Ghost模块融合后，参数量和计算量进一步降低，检测精度也小幅提升。联合轻量化主干DW-HGNetV2与LSDEDH后，mAP@0.5:0.95提升至83.87%，精确率也有较大提升，验证了局部纹理建模与多尺度特征的互补性。OD-C3Ghost模块与LSDEDH的组合将参数量降至5.36M，计算量降低了44.7%，召回率达到了97.93%，凸显了它们的轻量化优势。集成3个模块后，模型所需参数量低至4.58M，计算量低至14.6G，同时mAP@0.5提升至99.30%，较基准模型提高了0.81%，mAP@0.5:0.95提升至83.80%，较基准模型提高了近4%，证明三者协同作用具备显著优势。最后，在引入NWD-PIoUV2后，模型在同等复杂度下，mAP@0.5进一步提升至99.41%，mAP@0.5:0.95达84.40%，精确率和召回率分别达98.2%和98.6%。DOLN-YOLO通过三重轻量化设计显著压缩了模型复杂度，尽管ODConv的动态感知机制、DEConv的多分支梯度融合以及NWD损失的高斯建模等动态计算操作导致推理速度小幅下降，但模型mAP@0.5:0.95提升了4.57%，mAP@0.5也有小幅提升，可见模型以可控的速度代价换取了精度与轻量化的阶跃式提升，实现了在有限资源场景中对复杂环境下条码的高鲁棒性识别。

### 2.3 主流模型的对比实验

为全面评估本研究提出模型的检测性能，本节将DOLN-YOLO模型与当前广泛使用的目标检测算法进行系统对比。所选对比模型包括经典的两阶段检测算法Faster R-CNN、单阶段算法代表SSD，以及YOLO系列中的多个先进版本，如YOLOv5s、YOLOv6s、YOLOv7-tiny和YOLOv11s。此外，本研究选取了近年来具有代表性的改进模型，如Wang等<sup>[26]</sup>提出的GOLD-YOLO，该模型通过信息聚焦-分发机制增强了对不同尺度目标的检测能力；Kang等<sup>[27]</sup>提出的ASF-YOLO，基于注意力尺度序列融合策略，显著提升了细胞等微小目标的识别性能；Qu等<sup>[28]</sup>提出的轻量级条码检测网络MGL-YOLO，通过引入多尺度群卷积增强了多尺度特征提取能力，在轻量化和检测精度之间实现了良好平衡。Wang等<sup>[29]</sup>基于状态空间模型构建

的Mamba-YOLO，在检测精度与泛化性方面均有显著提升；以及Qin等<sup>[30]</sup>针对移动设备设计的通用高效架构MobileNetV4，结合通用倒瓶颈模块和移动多查询注意力机制，在推理速度和检测精度方面实现了双重提升。

上述模型均在其各自研究中报告了优异的性能，代表了当前目标检测领域的不同技术路线与优化方向。将其纳入对比能够全面检验DOLN-YOLO在不同检测场景下的综合性能，尤其是多尺度目标适应能力、小目标敏感度和计算效率等方面。特别地，DOLN-YOLO与MobileNetV4和MGL-YOLO一致，均致力于实现模型的轻量化，但不同之处在于DOLN-YOLO并未直接采用现有通用模块，而是面向条形码检测任务进行了针对性结构设计，在保持轻量化的同时增强了对特定特征的提取能力。在多尺度与复杂形态感知方面，DOLN-YOLO与GOLD-YOLO和ASF-YOLO模型共同关注尺度适应与形态鲁棒性，但DOLN-YOLO主要通过融合动态卷积与轻量化结构提升对几何畸变的适应能力，而非依赖注意力或特征分发机制。此外，相较于Mamba-YOLO侧重架构创新的方法，DOLN-YOLO在损失函数层面提出了更具针对性的优化策略，通过联合归一化Wasserstein距离与动态IoU损失，有效缓解了检测中微小定位偏差带来的优化问题。

实验数据如表3所示。实验数据表明，该模型在精度与效率维度均实现显著优化：其99.41%的mAP@0.5与84.40%的mAP@0.5:0.95在对比体系中保持领先，同时以4.58M参数量、14.60GFLOPs及9.80MB模型体积达成优异计算效率，有效平衡了轻量化部署与高精度检测的协同需求。

### 2.4 可视化分析

为更加直观地感受DOLN-YOLO模型在条形码检测任务上带来的性能提升，本节首先绘制了DOLN-YOLO模型与YOLOv8s模型的mAP@0.5和mAP@0.5:0.95曲线对比图，而后列举了不同检测模型的条形码检测效果图。

#### 1) 曲线对比图

DOLN-YOLO模型与YOLOv8s模型的mAP@0.5和mAP@0.5:0.95曲线对比图分别如图12和图13所示。

mAP@0.5与mAP@0.5:0.95作为评估模型在不同交并比阈值下检测性能的关键指标，其对比曲线清晰表明：DOLN-YOLO在两项指标上均全面超越基准模型。该模型在训练初期即确立显著优势，印证了其浅层特征优化设计的有效性；同时，其曲线振荡幅度明显小于基准模型，进一步验证了架构设计带来的强稳定性。

#### 2) 检测效果对比图

本节使用复杂背景下的条形码图像，包含小目标、遮挡、褶皱、模糊、不均匀光影和残缺等复合影响因素。检测效果对比如图14所示。

表 3 主流模型对比实验结果

Table 3 Comparison of mainstream model experimental results

模型	mAP@0.5/%	mAP@0.5:0.95/%	Params/ $10^6$	FLOPs/G	Model Size/MB
Faster R-CNN	98.95	81.70	136.80 M	369.60	521.00
SSD	95.61	72.66	24.10 M	61.00	90.60
YOLOv5s	98.06	80.12	7.01 M	15.80	13.60
YOLOv6s	97.13	79.68	16.30 M	44.00	31.30
YOLOv7-tiny	95.89	75.44	6.01 M	13.00	11.70
YOLOv8s	98.49	79.83	11.13 M	28.40	21.40
YOLOv11s	98.65	80.87	9.4 M	21.50	54.40
MobileNetV4	98.18	81.06	2.92 M	9.85	11.20
MGL-YOLO	97.87	78.61	<b>1.92 M</b>	<b>5.40</b>	<b>3.92</b>
GOLD-YOLO	96.46	75.85	5.60 M	12.10	177.00
ASF-YOLO	97.52	79.23	47.10 M	115.90	90.30
Mamba-YOLO	96.55	74.97	5.98 M	14.00	11.70
Ours(DOLN-YOLO)	<b>99.41</b>	<b>84.40</b>	4.58 M	14.60	9.80

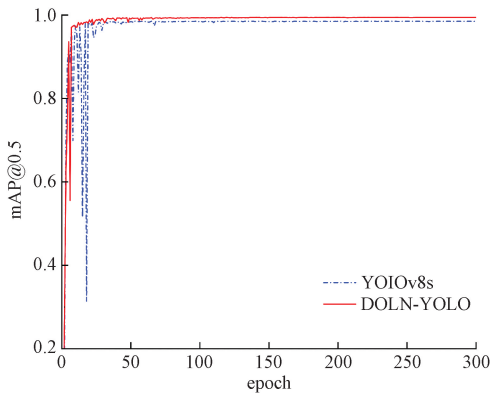


图 12 mAP@0.5 曲线对比

Fig. 12 Comparison of mAP@0.5 curves

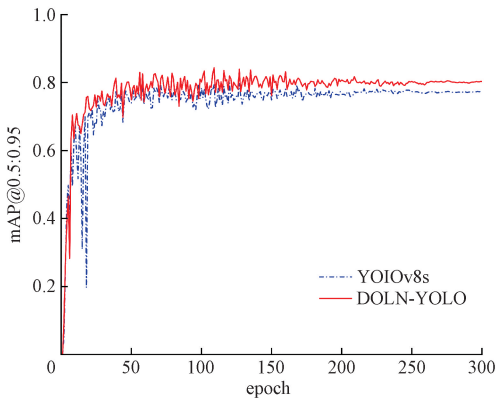


图 13 mAP@0.5:0.95 曲线对比

Fig. 13 Comparison of mAP@0.5:0.95 curves

由图 14 可知, DOLN-YOLO 能够在复杂程度不同的场景中精准检测条形码。在第 1 列和第 2 列小目标和遮挡条形码检测中, 只有 Faster R-CNN 和 DOLN-YOLO 完整

检测出所有目标, 其余检测模型均存在漏检现象。在第 3 列含有相似目标场景的检测中, Faster R-CNN、SSD、YOLOv6s、YOLOv7-tiny 和 MGL-YOLO 均出现了误检现象。在第 5 列的残缺条形码检测场景中, DOLN-YOLO、YOLOv11s、YOLOv5s 和 Faster R-CNN 均检测出了两个较小部分的条形码, YOLOv8s 和 MobileNetV4 只检测到到一个, 而其余模型均为检测到。对比结果表明, DOLN-YOLO 模型在各种复杂环境中表现出很强的条形码检测能力。

综上所述, DOLN-YOLO 凭借其特征提取框架和优化机制, 检测效果优于其他模型。DW-HGNetV2 通过 DWConv 重构多尺度纹理建模, 增强了遮挡和小目标特征地捕获能力; OD-C3Ghost 模块融合 ODConv 与 Ghost 卷积, 提升了对形变与相似干扰的判别鲁棒性; LSDEDH 检测头基于梯度-强度双路特征融合与细节增强卷积, 实现了精准定位残缺条码碎片; NWD-PIoUV2 损失函数联合归一化 Wasserstein 距离与改进交并比度量, 优化了模糊条码场景的定位精度。

### 3) 轻量化设备部署效果图

为评估 DOLN-YOLO 模型在移动端低算力设备上的实际性能, 本研究以 Raspberry Pi5 为边缘部署平台, 开展模型适配与系统实现。针对该嵌入式设备的存储和算力限制, 本研究对 DOLN-YOLO 模型进行了两项关键优化: 首先, 采用训练后量化(PTQ)将原 FP32 模型转换为 INT8 格式, 在基本保持精度的同时显著压缩模型体积并降低推理延迟; 其次, 集成 ONNX Runtime 轻量推理引擎, 实现对量化模型的高效加载与硬件加速推理。在此基础上, 基于 PyQt5 开发了具备实时条码检测功能的图形交互界面。实际部署结果如图 15 所示, 该系统在 Raspberry Pi5 中能够保持较高的识别精度, 并能满足实时检测的基本要求,



图 14 检测效果对比

Fig. 14 Comparison of detection results

验证了 DOLN-YOLO 在物联网及移动终端条码识别任务中的轻量化特性与部署实用性。

### 3 结 论

针对现有检测模型在检测复杂环境下条形码时易受干扰导致误检、漏检,精度不足且模型复杂度高、难以部署于移动端低算力设备的问题,本研究基于 YOLOv8 提出了一种轻量级且高精度目标检测算法 DOLN-YOLO。首先,引入了 DWConv 重构 HGNetV2 主干并替换原主干网络,在保留多尺度特征建模能力的同时,显著降低参数数量和计算量;其次,构建了 OD-C3Ghost 模块代替 C2f 模块,通过融合 ODConv 的动态感知机制与 ChostConv 的轻量化特性,在降低模型复杂度的同时提升模型对透视畸变、曲面变形的适应性;然后,设计了 LSDEDH 检测头,集成 GN

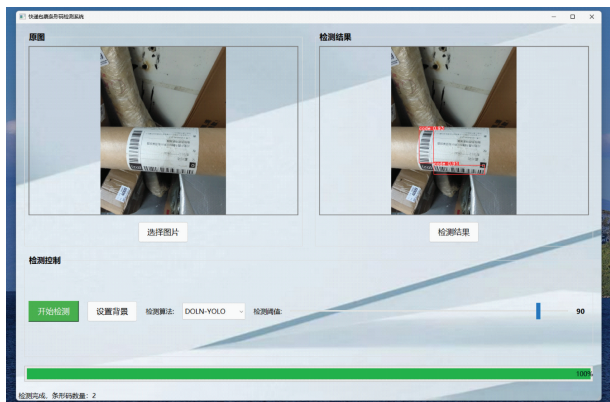


图 15 检测结果界面

Fig. 15 Detection result interface

与DEConv,通过梯度-强度双流特征融合增强了遮挡和模糊场景下的条形码碎片重组能力;最后,提出了NWD-PIoUV2复合损失函数,联合归一化 Wasserstein 距离与动态聚焦 PIoUV2 损失,缓解微小位置偏差的梯度突变问题。

实验结果表明,DOLN-YOLO在复杂环境下的条码检测方面表现出色,同时具备显著的轻量化优势,更利于低算力及移动端设备部署。本研究为物流、医疗、零售等场景实现高鲁棒检测与高效移动部署的协同优化提供了有效方案。需要指出的是,提升精度与轻量化的同时增加了模型结构复杂性,导致检测速度略有下降,未来研究需在性能与效率间寻求更优平衡。

## 参考文献

- [1] 郭广振,张丰收.基于机器视觉的快递面单识别[J].包装与食品机械,2023,41(3):65-69,74.  
GUO G ZH, ZHANG F SH. Recognition of express delivery labels based on machine vision[J]. Packaging and Food Machinery, 2023, 41(3): 65-69,74.
- [2] 梁列全,李想,何永华,等.基于改进YOLOv10n的泊车图像旋转目标检测算法[J].电子测量技术,2025,48(19):205-216.  
LIANG L Q, LI X, HE Y H, et al. Parking image rotation target detection algorithm based on improved YOLOv10n[J]. Electronic Measurement Technology, 2025,48(19):205-216.
- [3] DAI J F, LI Y, HE K M, et al. R-FCN: Object detection via region-based fully convolutional networks[C]. Neural Information Processing Systems, 2016:379-387.
- [4] TERVEN J, ESPARZA C M D, GONZÁLEZ R A J. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS[J]. Machine Learning and Knowledge Extraction, 2023, 5(4): 1680-1716.
- [5] LI Y, HE L, ZHANG M, et al. Improving the performance of the single shot multibox detector for steel surface defects with context fusion and feature refinement[J]. Electronics, 2023, 12(11):2440.
- [6] ZHANG J, MIN X, JIA J, et al. Fine localization and distortion resistant detection of multi-class barcode in complex environments [J]. Multimedia Tools and Applications, 2020, 80(11): 1-20.
- [7] KOLEKAR A, DALAL V. Barcode detection and classification using SSD(single shot multibox detector) deep learning algorithm [C]. 3rd International Conference on Advances in Science & Technology (ICAST),2020.
- [8] XU X, XUE ZH P, ZHAO Y. Research on an algorithm of express parcel sorting based on deeper learning and multi-information recognition [J]. Sensors, 2022, 22(17): 6705.
- [9] 周为鹏,徐白,龚佳卿,等.基于深度学习的条码识别算法[J].电子技术与软件工程,2021(19):184-185.  
ZHOU W P, XU B, GONG J Q, et al. Barcode recognition algorithm based on deep learning [J]. Electronic Technology and Software Engineering, 2021(19): 184-185.
- [10] LI J, ZHAO Q, TAN X, et al. Using deep ConvNet for robust 1D barcode detection [C]. International Conference on Intelligent and Interactive Systems and Applications. Cham: Springer International Publishing, 2017: 261-267.
- [11] 王正家,丁聪,庄健,等.基于改进YOLOv7-tiny的轻量级条码检测算法[J].印刷与数字媒体技术研究,2025(1):71-81.  
WANG ZH J, DING C, ZHUANG J, et al. A lightweight barcode detection algorithm based on an improved YOLOv7-tiny[J]. Research on Printing and Digital Media Technology, 2025(1): 71-81.
- [12] 黄勇,陈明.基于改进的YOLOv8算法的二维码和条形码检测方法[J].信息技术与信息化,2024(3):196-199.  
HUANG Y, CHEN M. A QR code and barcode detection method based on an improved YOLOv8 algorithm[J]. Information Technology and Informatization, 2024(3): 196-199.
- [13] 朱圣博,魏利胜,高港,等.基于改进YOLOv8s的光学遥感小型船舶检测算法[J].电子测量与仪器学报,2024,38(10):48-57.  
ZHU SH B, WEI L SH, GAO G, et al. An improved YOLOv8s-based optical remote sensing algorithm for small vessel detection [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (10): 48-57.
- [14] MIAO Q N, WANG T H, WANG R. Intelligent factory vehicle detection algorithm based on improved YOLOv8[J]. Instrumentation, 2025, 12(2): 60-70.
- [15] 陈俊生,陈沂蒙,刘明杰,等.基于MFES-YOLOv8n的光伏电池缺陷检测方法[J].仪器仪表学报,2025,46(6):251-262.  
CHEN J SH, CHEN Y M, LIU M J, et al. A defect detection method for photovoltaic cells based on MFES-YOLOv8n[J]. Chinese Journal of Scientific Instrument, 2025,46(6):251-262.
- [16] ZHANG L, ZHENG J CH, LI CH P, et al. CCDN-DETR: A detection transformer based on constrained

- contrast denoising for multi-class synthetic aperture radar object detection[J]. *Sensors*, 2024, 24(6): 25.
- [17] XU W G, LIU J H, HE Y, et al. Deep learning model for cold-rolled plate defect detection based on omni-dimensional dynamic convolution and global attention mechanism enhancement [J]. *Metallurgical and Materials Transactions B*, 2025, 56(4): 1-17.
- [18] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 1577-1586.
- [19] TIAN ZH, SHEN CH H, CHEN H, et al. FCOS: Fully convolutional one-stage object detection[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019:9626-9635.
- [20] CHEN Z X, HE Z W, LU ZH M. DEA-Net: Single image dehazing based on detail-enhanced convolution and content-guided attention [J]. *IEEE Transactions on Image Processing*, 2024,33: 1002-1015.
- [21] 宋树成, 程换新. 基于改进YOLOv8的遥感图像检测算法[J]. *电子测量技术*, 2025, 48(3): 52-59.
- SONG SH CH, CHENG H X. An improved YOLOv8-based detection algorithm for remote sensing images [J]. *Electronic Measurement Technology*, 2025, 48(3): 52-59.
- [22] ZHENG Z, WANG P, LIU W, et al. Distance-IoU Loss: Faster and better learning for bounding box regression [C]. *AAAI Conference on Artificial Intelligence*, 2020, 34(7): 12993-13000.
- [23] LIU C, WANG K G, LI Q, et al. Powerful-IoU: More straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism [J]. *Neural Networks*, 2024: 170:276-284.
- [24] WANG J W, XU C, YANG W, et al. A normalized Gaussian wasserstein distance for tiny object detection[J]. *ArXiv preprint arXiv:2110.13389*, 2021.
- [25] 赵佰亭, 张敏, 贾晓芬. YOLOv8n-CSG:轻量化钢材表面缺陷检测算法[J]. *电子测量与仪器学报*, 2025, 39(8):115-125.
- ZHAO B T, ZHANG M, JIA X F. YOLOv8n-CSG: A lightweight algorithm for steel surface defect detection[J]. *Journal of Electronic Measurement and Instrumentation*, 2025,39(8):115-125.
- [26] WANG CH CH, HE W, NIE Y, et al. Gold-YOLO: Efficient object detector via gather-and-distribute mechanism [J]. *Advances in Neural Information Processing Systems*, 2023, 36: 51094-51112.
- [27] KANG M, TING C M, TING F F, et al. ASF-YOLO: A novel YOLO model with attentional scale sequence fusion for cell instance segmentation [J]. *Image and Vision Computing*, 2024, 147:105057.
- [28] QU Y H, ZHANG F SH. MGL-YOLO: A lightweight barcode target detection algorithm [J]. *Sensors*, 2024, 24(23): 7590.
- [29] WANG Z Y, LI C, XU H Y, et al. Mamba YOLO: SSMs-based YOLO for object detection [J]. *ArXiv preprint arXiv:2406.05835*, 2024.
- [30] QIN D F, LEICHTNER C, DELAKIS M, et al. MobileNetV4: Universal models for the mobile ecosystem [C]. *European Conference on Computer Vision*. Cham: Springer Nature Switzerland, 2024: 78-96.

## 作者简介

何奥辉, 硕士研究生, 主要研究方向为目标检测、智能制造等。

E-mail: he15938681625@163.com

张丰收(通信作者), 博士, 教授, 主要研究方向为机器视觉、数控技术、智能制造等。

E-mail: fengshouzhang@163.com

庄高帅, 硕士研究生, 主要研究方向为目标检测、智能制造等。

E-mail: zgs17634506030@163.com

段庆阳, 硕士研究生, 主要研究方向为目标检测、智能制造等。

冯宝阳, 硕士研究生, 主要研究方向为目标检测、智能制造等。