

DOI: 10.11835/j.issn.2096-6717.2026.033



开放科学(资源服务)标识码 OSID:



LPR-YOLO:轻量化钢筋截面检测方法

沈益俊¹, 刘吉敏^{1,2}, 鲁向阳¹, 季燕春¹

(1. 安徽理工大学土木建筑学院, 安徽淮南 232000; 2. 矿山深井建设技术国家工程研究中心, 北京 100013)

摘要:针对预制梁厂钢筋盘点场景中存在的密集堆叠、相互遮挡、难以清点以及现有深度学习检测模型参数量大、难以在边缘设备部署等问题,提出一种基于YOLOv8n的轻量化密集钢筋截面检测方法:LPR-YOLO。该方法利用Ghost模块重构YOLOv8n的主干网络,通过高效线性运算替代部分标准卷积,在保证特征提取有效性的同时大幅降低模型的参数量与计算冗余;在颈部网络嵌入卷积块注意力机制(CBAM),从通道和空间两个维度增强模型对钢筋截面关键特征的聚焦能力,抑制复杂背景噪声及光照对钢筋截面的干扰。结果表明,LPR-YOLO的mAP@0.5达到94.8%,相较于原始基线模型提高了2.2%,同时模型参数量和计算量分别降低了 1.3×10^6 和3GFLOPs。在强光干扰、泥污遮挡等复杂工况下,LPR-YOLO也拥有较优秀的泛化能力。

关键词:钢筋截面;注意力机制;YOLOv8;轻量化网络;Ghost模块

中图分类号:TU511.3 **文献标志码:**A **文章编号:**2096-6717(XXXX)XX-0001-10

LPR-YOLO: A lightweight method for dense rebar section

SHEN Yijun¹, LIU Jimin^{1,2}, LU Xiangyang¹, JI Yanchun¹

(1. School of Civil and Architectural Engineering, Anhui University of Science and Technology, Huainan 232000, Anhui, P. R. China; 2. National Engineering Research Center of Deep Shaft Construction, Beijing 100013, P. R. China)

Abstract: To address the challenges of dense stacking, mutual occlusion, and the difficulty of deploying heavy deep learning models on edge devices in prefabricated beam yard rebar inventory scenarios, this paper proposes a lightweight dense rebar cross-section detection method named LPR-YOLO, based on YOLOv8n. Firstly, the method reconstructs the backbone network of YOLOv8n using Ghost modules, which replace standard convolutions with cheap linear operations to significantly reduce model parameters and computational redundancy while maintaining feature extraction effectiveness. Secondly, the Convolutional Block Attention Module (CBAM) is integrated into the neck network to enhance the model's focus on key rebar cross-section features from both channel and spatial dimensions, effectively suppressing complex background noise and

收稿日期:2026-01-20

基金项目:矿山深井建设技术国家工程研究中心开放研究基金(NERCDCS-2024001);建筑结构与地下工程安徽省重点实验室开放课题(KLBSUE-2022-01);国家级一流本科课程(2023240791)

作者简介:沈益俊(2002-),男,主要从事视觉识别和井壁稳定性研究,E-mail:xuexishen632@gmail.com。

刘吉敏(通信作者),女,博士,教授,E-mail:jimliu@aust.edu.cn。

Received: 2026-01-20

Foundation items: National Engineering Research Center of Deep Mine Construction Technology Open Research Fund (No. NERCDCS-2024001); Anhui Provincial Key Laboratory of Building Structures and Underground Engineering Open Project (No. KLBSUE-2022-01); National First-Class Undergraduate Course (No. 2023240791)

Author brief: SHEN Yijun (2002-), main research interests: visual recognition and wellbore stability, E-mail: xuexishen632@gmail.com.

LIU Jimin (corresponding author), PhD, professor, E-mail: jimliu@aust.edu.cn.

lighting interference. The experimental results show that LPR-YOLO achieved an mAP@0.5 of 94.8%, which is a 2.2% improvement compared to the original baseline model, while the model parameters and GFLOPs were reduced by 1.3M and 3, respectively. LPR-YOLO also demonstrates excellent generalization ability under complex conditions such as strong light interference and mud occlusion.

Keywords: rebar counting; attention mechanism; YOLOv8; lightweight network; Ghost module

随着基础设施建设的持续推进,预制装配式桥梁因其施工效率高、质量可控性强等优势,在现代交通工程中占据越来越重要的地位。预制梁厂作为桥梁构件的集中生产场所,其物料管理的精细化水平直接关系到装配式桥梁工程的进度与成本控制^[1-3]。因此,快速准确地清点成捆钢筋数量、有效检测密集钢筋截面是一项至关重要的基础工作。

在传统工作流程中,人工逐根计数是钢筋清点的主流方式。现场人员需在钢筋堆场中徒手翻找、目视计数,劳动强度大、效率低下,单次清点耗时平均超过 30 min。工程调研表明,人工清点的误差率可达 5%~8%,在钢筋密集捆扎(每捆超过 50 根)的情况下误差率甚至超过 10%^[3-4]。这种粗放的管理方式已难以满足现代预制梁厂对材料管理精细化、信息化的迫切需求。

近年来,随着计算机视觉技术的日益成熟,基于图像处理的自动化计数方法逐渐成为研究热点。针对密集钢筋截面检测问题,研究方法大体可以分为两类。一类是基于传统图像处理算法,如边缘检测、霍夫变换或分水岭分割等^[5-6]。这类方法在图像质量高、背景干净、钢筋截面分离良好的理想条件下能取得一定效果,但其鲁棒性较差。同时在高密度堆叠场景下,钢筋间严重的相互遮挡与粘连导致边界模糊,使得依赖浅层特征的传统检测算法难以有效分离目标,漏检率居高不下。

另一类是基于深度学习的目标检测算法^[7-13],虽较传统方法具有更强的抗干扰能力,但在钢筋检测场景中仍存在一定局限。一方面,模型对数据依赖较强,密集钢筋场景下标注成本较高,极端工况下的泛化能力仍有提升空间;另一方面,在成捆钢筋高度堆叠条件下,通用模型对细粒度截面特征的提取能力有限。此外,预制梁厂钢筋盘点位置分散,现场环境通常难以提供高算力平台,因此检测模型在保证精度的同时,还需兼顾较低的参数量与计算复杂度,以适应低算力设备部署需求。与此同时,钢筋盘点往往涉及不同区域、批次和规格钢筋的连续检测与统计,若推理耗时过长,将影响现场作业效率。因此,模型轻量化是实现预制梁厂钢筋自动清点低成本、高效率应用的重要基础。

通用轻量化模型如 MobileNet、ShuffleNet 虽能

降低计算复杂度,但在密集遮挡场景下检测精度不足。部分研究尝试引入注意力机制增强特征判别力,但针对钢筋截面的特征提取与成捆数量统计的优化研究仍属空白^[10]。因此,亟须一种面向预制梁厂场景的轻量化钢筋检测计数优化方法,在保障清点精度的同时满足边缘端部署需求,为智慧梁厂仓库管理建设提供关键技术支持。

笔者以 YOLOv8 为基线框架,提出轻量化密集钢筋截面检测模型 LPR-YOLO,其主要工作包括:提出一种融合 GhostNet 与 CBAM 的轻量化钢筋检测新模型 LPR-YOLO,模型在主干网络利用 GhostNet 大幅削减计算冗余,同时颈部网络通过 CBAM 聚焦关键特征以补偿精度损失;构建一个包含多种复杂工况的钢筋截面专用数据集,该数据集源于真实的预制梁厂环境,涵盖了强光干扰、截面锈蚀、泥污遮挡及不同光照条件,通过全面的实验,验证模型的先进性与实用性。

1 YOLOv8n 模型

YOLOv8 凭借高精度和低延迟的推理能力,已成为工业检测领域的优选网络。其在实时性要求严苛的场景中表现尤为突出。YOLO 算法体系在智能监控、自动驾驶等行业应用中已被充分验证,取得了显著成果^[14]。发展至今,YOLOv8 系列根据参数规模和具体功能分为 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x 等多种结构。其中 YOLOv8n 在保持模型精度的同时参数量较小,因此本文选择 YOLOv8n 作为轻量化基线模型进行实验和进一步部署应用。

YOLOv8n 的网络架构主要涵盖三大核心模块:用于特征提取的主干网络(Backbone)、负责多尺度特征整合的融合网络(Neck)以及执行最终预测的检测头(Head)。在数据输入主干网络之前,首先经过预处理阶段,输入图像首先被统一缩放到 640×640 分辨率。主干网络基于 C2f(Cross-stage partial connections with 2 convolutions)模块构建,每个模块包含 Conv2D+BatchNorm+SiLU 结构,并采用梯度分流机制,其中 Conv(卷积)作为网络架构的基本组成元素。颈部网络(Neck)接收来自骨干网络的特征输出,借助 SPPF(快速空间金字塔池

化)模块完成上下文信息的跨尺度聚合,并采用上采样(Upsample)与特征拼接(Concat)策略实现多层次特征融合,从而增强语义表达能力^[15]。检测头(Head)则沿用无锚点(Anchor-Free)结构,引入损失函数(Distribution Focal Loss)与匹配机制(Task-Aligned Assigner),对多尺度目标实施检测以获得更优性能。

2 LPR-YOLO

针对仓储入库过程中钢筋密集堆放、相互遮挡

导致的漏检和错检,以及模型难以在边缘设备部署等问题,以YOLOv8n为基线模型,设计出LPR-YOLO。如图1所示,LPR-YOLO的整体架构在YOLOv8n的基础上进行了轻量化重构。数据流首先进入主干网络,其中原有的C2f模块被Ghost模块^[16-19]所替代,以在降低计算量的同时生成丰富的特征图。随后,特征图进入颈部网络,在此阶段,将CBAM模块^[20]嵌入到每一层特征融合之前。这种设计使得网络在进行上采样和特征拼接时,能够优先处理经过注意力加权的显著特征,最后由检测头输出预测结果。

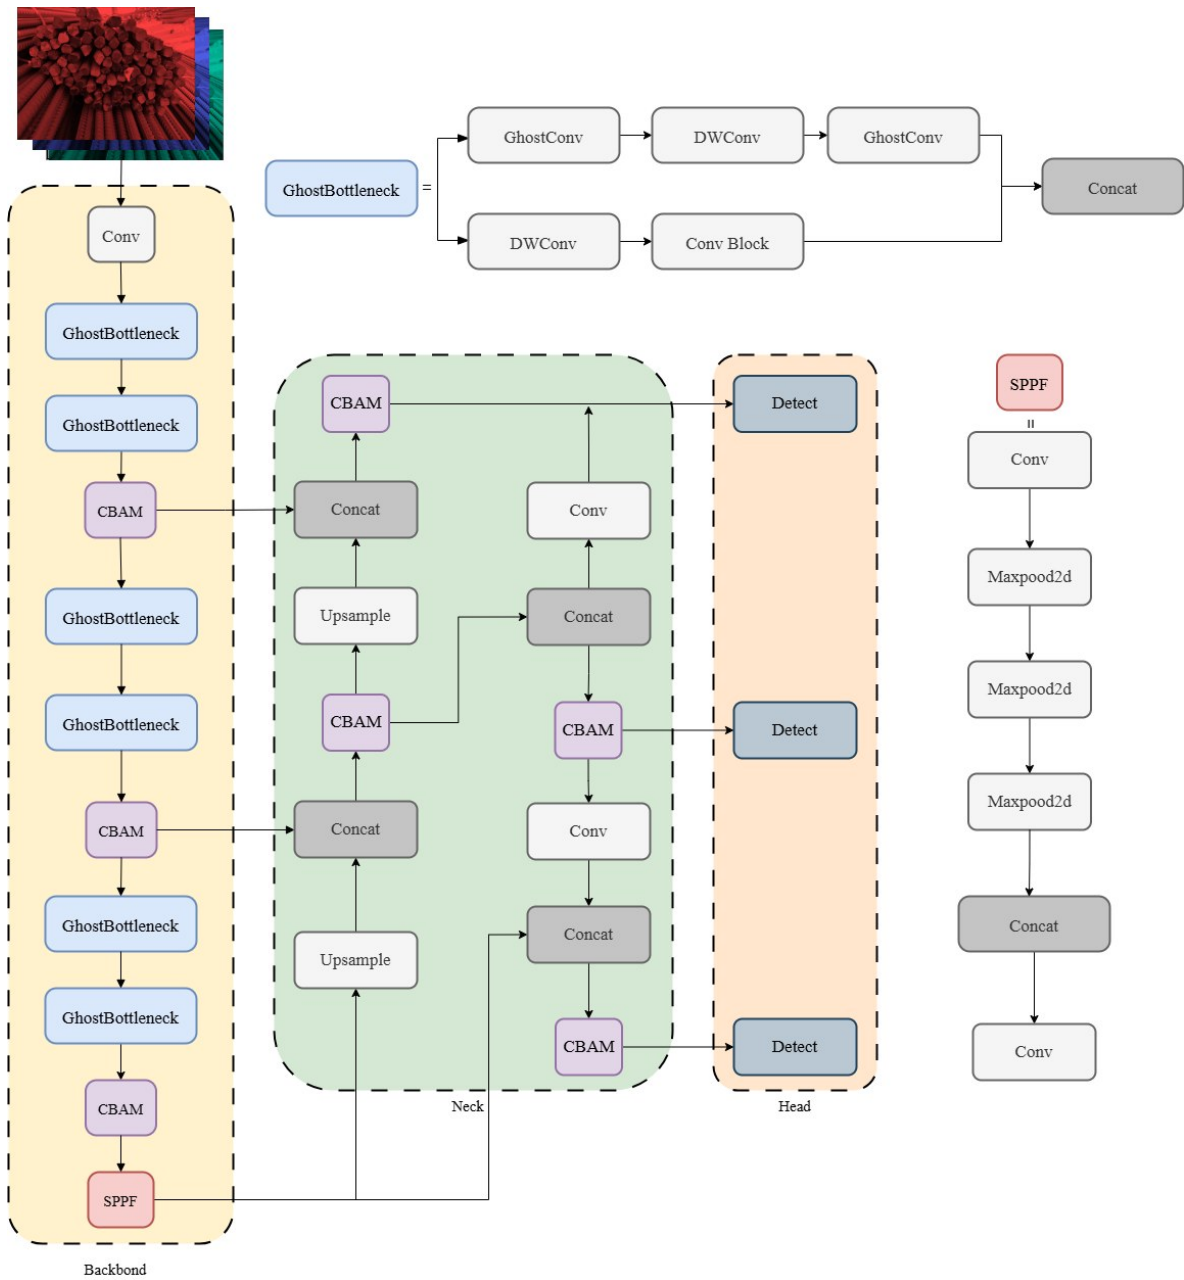


图1 LPR-YOLO网络结构图

Fig.1 Network architecture diagram of LPR-YOLO

2.1 基于Ghost模块的轻量化主干网络

考虑到常规卷积生成的特征图中存在大量冗

余信息,引入Ghost模块作为核心卷积单元。目标在于保证特征提取能力的同时,降低模型的参数量

与计算复杂度。

Ghost 模块将标准卷积分为两步,首先使用一次标准卷积(通常是 1×1 卷积)。然后,对第一步生成的每一个内在(intrinsic)特征图,进行一系列轻量级的线性变换(Cheap Linear Operations),从而生成更多的特征图。

此类线性变换往往采用深度可分离卷积(Depthwise Convolution)实现,这主要归因其极低的计算开销。最后将第1步生成的 intrinsic 特征图和第2步生成的特征图拼接在一起,得到与标准卷积输出通道数相同的最终输出,但其计算成本却大大降低。具体计算流程如下:假设标准卷积生成的特征图为

$$Y_p = \text{Conv}(X, W_p) \quad (1)$$

式中: $X \in \mathbb{R}^{h \times w \times c}$ 为输入特征, W 为卷积核, $Y \in \mathbb{R}^{h' \times w' \times n}$ 为输出特征,总体计算复杂度为 $O(h'w'ck^2n)$ 。之后对每个主特征 y_i ,通过高效线性变换生成 s 个 Ghost 特征

$$y_{i,j} = \Phi_j(y_i), \quad j = 1, 2, \dots, s \quad (2)$$

最终输出

$$Y = \text{Concat}(Y_p, Y_g) \quad (3)$$

其中

$$Y_g = \{y_{i,j} | 1 \leq i \leq m, 1 \leq j \leq s\}$$

最终通道为 $n = m \times s$

对比标准卷积计算量和 Ghost 模块计算量

$$F_{\text{conv}} = h'w'k^2cn \quad (4)$$

$$F_{\text{ghost}} = h'w'k^2cm + h'w'd^2m(s-1) \quad (5)$$

式中: d 是 Ghost 变换的核尺寸,且因为 $m < n$ 且 $d \ll k$,所以

$$F_{\text{ghost}} \ll F_{\text{conv}} \quad (6)$$

相较于常规卷积,Ghost 模块更适合部署资源受限场景,有助于提升模型在边缘设备上的运行效率。模块具体结构如图2所示。

2.2 CBAM 模块

针对钢筋截面目标密集、尺度较小且易受背景干扰的问题,在特征融合阶段引入 CBAM 注意力机制(Convolutional Block Attention Module, CBAM),以增强模型对关键区域和判别性特征的关注能力^[21]。CBAM 通过联合建模通道注意力与空间注意力,对特征图进行自适应加权,从而抑制无关背景响应并突出钢筋截面区域。

CBAM 模块的输入为中间特征图 $F \in \mathbb{R}^{C \times H \times W}$,首先通过通道注意力模块(CAM)在通道维度上建模特征重要性;随后通过空间注意力模块(SAM)在空间维度上增强显著区域。通道特征图加权 F' 和空间特征图加权 F'' 为

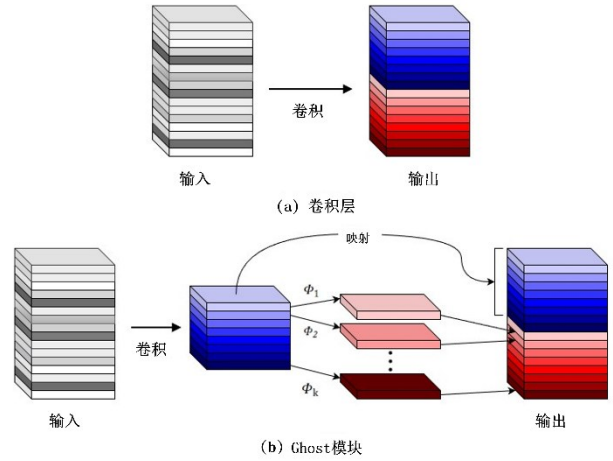


图2 Ghost卷积与传统卷积方式对比

Fig.2 Comparison between ghost convolution and traditional convolution methods

$$F' = M_c(F) \otimes F \quad (7)$$

$$F'' = M_s(F') \otimes F' \quad (8)$$

式中: $M_c \in [0, 1]^{C \times 1 \times 1}$ 为通道注意力图, $M_s \in [0, 1]^{1 \times H \times W}$ 为空间注意力图, \otimes 为逐元素乘法。

在卷积特征中,不同通道往往代表不同类型的语义信息,如颜色、边缘、纹理等。然而,卷积层通常对所有通道采用相同权重处理,缺乏选择性。为刻画通道间的内在关联性并突出关键特征通道,通道注意力通过对输入特征施加全局平均池化与最大池化操作,分别构建两种通道描述。

$$F_{\text{avg}}^c = \text{AvgPool}(F), \quad F_{\text{max}}^c = \text{MaxPool}(F),$$

其中: $f_{\text{avg}}, f_{\text{max}} \in \mathbb{R}^{C \times 1 \times 1}$ 。

然后通过共享权重的两层全连接网络计算通道注意力

$$M_c(F) = \sigma(W_1(\delta(W_0(f_{\text{avg}}))) + W_1(\delta(W_0(f_{\text{max}})))) \quad (9)$$

其中 r 为通道压缩率(取 $r = 16$); $\delta(\cdot)$ 为ReLU激活函数; $\sigma(\cdot)$ 为Sigmoid函数。该公式本质上实现了一个非线性通道映射函数

$$M_c = f_c(F) = \sigma(g_{\text{MLP}}(f_{\text{avg}}, f_{\text{max}})) \quad (10)$$

得到的通道权重 M_c 表示每个通道的重要性系数,利用通道权重对原特征图加权得到

$$F' = M_c(F) \otimes F$$

此操作等价于一种“自适应归一化”,增强高响应通道的贡献,并抑制背景或噪声通道,有效地避免钢筋识别过程中明暗背景带来的过曝和灰暗导致的识别精度下降。

在通道加权后,仍存在空间位置上的特征冗余。不同像素区域在视觉语义上具有不同的重要性,例如目标主体通常集中在局部区域,而背景包

含大量无用信息。空间注意力模块旨在引导网络在二维空间上聚焦于目标显著区域,具体操作过程如下。

首先对通道加权后的特征图 F' 沿通道维度执行平均池化和最大池化,获得两个单通道空间特征图。

$$f_{\text{avg}}^s = \text{AvgPool}(F', \text{dim} = C) \quad (11)$$

$$f_{\text{max}}^s = \text{MaxPool}(F', \text{dim} = C) \quad (12)$$

接着将二者拼接,并通过一个 7×7 卷积进行特征融合

$$f_{\text{cat}} = [f_{\text{avg}}^s; f_{\text{max}}^s] \quad (13)$$

$$M_s(F') = \sigma(f^{7 \times 7}(f_{\text{cat}})) \quad (14)$$

其中卷积核 $f^{7 \times 7}$ 捕获局部空间上下文信息, Sigmoid

激活确保权重在 $[0, 1]$ 范围内,最终空间注意力将原特征按位置加权得到 F'' 为

$$F'' = M_s(F') \otimes F'$$

综上所述, CBAM 模块结构流程如图 3 所示。首先,输入特征图 F 进入通道注意力子模块,经过全局最大池化和平均池化后,通过共享 MLP 生成通道权重 M_c ,对输入进行一维加权。随后,经过通道细化的特征图进入空间注意力模块,如图 3 下方所示,通过沿通道轴的池化操作和 7×7 卷积层,生成空间权重图 M_s ,最终输出同时包含通道和空间上下文信息的精炼特征。这一过程使得模型更加关注目标区域,通过捕捉特征间的空间关联来构建空间注意力分布图。相较于通道注意力,空间注意力更强调位置细节,从而与通道注意力实现有效互补。




图 3 CBAM 模块网络结构图

Fig.3 CBAM module network diagram

在复杂的施工环境中,空间注意力可以帮助模型学习到钢筋表面的锈蚀面、金属切割区域,并分配给这些区域更高的权重,同时抑制背景中无关区域的权重,从而有效减少误检。当钢筋相互遮挡或密集排列时, CBAM 通过其双重注意力机制,精细地分析特征图,帮助模型应对遮挡干扰,并聚焦于每个独立钢筋最显著的部分,从而提升在密集场景下的检测性能。

3 实验结果展示与分析

3.1 数据集来源

数据集照片采用预制梁厂内的库存钢筋,此部分钢筋用于预制构件的生产,对捆扎钢筋截面进行标注,构建密集钢筋截面数据集。其中截面类型包

括锈蚀截面、切割回火截面、金属反光截面、被污染截面等。原始图像由智能手机和工业相机采集,分辨率范围为 $1\,920 \times 1\,080$ 至 $3\,000 \times 4\,000$,采集过程涵盖了 3 种典型光照,分别为室外自然光,室内明亮库房以及室内及夜间弱光。拍摄距离控制在 $0.5 \sim 2$ m 之间。同时,为了模拟实际盘点时的不同视角,采集了正对截面 90° 和倾斜 $30^\circ \sim 60^\circ$ 两种视角的图像,以增强模型对透视变形的鲁棒性。

实验使用开源标注工具 LabelImg 对图像中的钢筋截面进行标注,类别统一为“rebar”。采用标准的矩形边界框进行标注,格式符合 YOLO 模型要求。针对密集堆叠导致的严重遮挡问题,标注过程坚持“可见即可标”的原则。对于部分可见的钢筋截面,标注框仅紧密包围其实际可见部分,而非凭

经验推断其完整轮廓。最终,共获得 563 张高质量图像,包含 69 249 个已标注的钢筋截面实例,部分

数据集展示如图 4 所示。




图 4 部分数据集展示

Fig.4 Dataset display

为能够更客观地评估模型在各种复杂工况下的真实性能。实验采用分层抽样策略。首先,根据场景类型和截面状态对全部图像进行分组。然后,在每个组内部分别按照 4:1 的比例进行随机抽样,最终形成包含 450 张图像的训练集和 113 张图像的测试集。

为了量化数据集的密集程度,对单张图像中的钢筋实例数量进行了统计。如图 5 所示,单张图像中的钢筋数量主要分布在 50~180 之间,平均每张图像包含约 123 个实例,部分极端样本超过 250 根,为检验模型对密集场景适应能力提供了合适样本。




图 5 单张图像钢筋数量分布直方图

Fig.5 Histogram of the distribution of rebar quantities in a single image

3.2 训练环境配置

在训练过程中,设置 batch size 为 8,初始学习率为 0.01,统一输入尺寸为 640×640,训练 100epochs。

实验所采用的软硬件参数如表 1 所示。

表 1 软硬件平台配置参数

Table 1 Hardware and software configuration

操作系统	GPU	RAM	CUDA	深度学习框架
Windows11	NVIDIA RTX 4060	16 G	CUDA 12.0	PyTorch 2.0

3.3 性能度量

模型评估涵盖复杂度与准确率两个维度,通过参数量和 GFLOPs(千兆浮点运算数)衡量其在资源受限平台的运行能力,二者越低代表模型越轻量;借助 mAP(平均精度均值)、Precision(精确率)及 Recall(召回率)评价检测效果,mAP 作为核心指标可综合反映模型在保持高精确率的同时实现高召回率的能力。Precision 用于衡量模型的检测准确性, P 值越高代表结果可信度越高,很少误检。Recall 用于衡量模型的检测能力,Recall 值越高意味着发生漏检的概率越低。计算式为

$$P = \frac{T_p}{T_p + F_p} \quad (15)$$

$$R = \frac{T_p}{T_p + F_n} \quad (16)$$

$$AP = \int_0^1 P(R) dR \quad (17)$$

式(15)中 T_p 为该模型正类预测为正类的样本, F_p 为负样本被误判为正例的样本数,式(16)中的 F_n 为正样本被错误分类为负类的计数。在本钢筋检测任务中,仅存在单一目标类别,故 mAP 指标退化为该类的 AP 值。采用平均精度均值 mAP@0.5 作

为模型检测性能评价指标之一。

3.4 消融实验

为评估各改进模块的有效性贡献,选取

YOLOv8n作为基准网络,并构建表2所示消融验证方案,最终结果列在表2中。

表2 消融实验结果

Table 2 Ablation experiment results

模型	Ghost	CBAM	参数量/ 10^6	GFLOPs	P/%	R/%	mAP@0.5/%
YOLOv8n			3.005	8.1	91.5	87.2	92.6
YOLO-ghost	✓		1.714	5.0	89.3	84.8	90.1
YOLO-CBAM		✓	3.008	8.1	94.8	91.3	96.6
LPR-YOLO	✓	✓	1.717	5.1	93.4	91.6	94.8

首先,单独引入Ghost模块后,模型的参数量和GFLOPs大幅降低,验证了其在轻量化方面的有效性。然而,其mAP@0.5却下降了2.5%。其原因在于:Ghost模块通过高效线性变换生成的高效特征图,虽然极大地提升了计算效率,但在捕捉复杂通道间相关性和细粒度特征方面能力较弱。对于钢筋截面这类小目标,其关键判别信息(如截面边界、锈蚀纹理,以及与背景的细灰度差异)可能会在特征压缩过程中被忽略,导致模型识别能力下降,尤其容易在密集堆叠区域产生漏检和误检。

与此相对,单独引入CBAM模块后,模型在参数量和计算量几乎不变的情况下,mAP@0.5显著提升了4.0%,达到96.6%。最关键的是,当二者结合形成LPR-YOLO时,模型不仅保持了轻量化的优势,mAP@0.5也达到了94.8%的优异性能,相较于基线提升了2.2%,CBAM模块弥补了Ghost模块带来的精度损失。其作用机理为通道注意力弥补了Ghost模块在通道信息提炼上的不足。它通过学习并增强钢筋截面的特征通道(如纹理、边缘通道),使得即便在被Ghost模块压缩的特征图中,关键信号也能被重新放大。其次,空间注意力则进一步聚焦于目标区域。它抑制了因特征模糊而可能被误认为钢筋的背景噪声,同时强化了每个独立钢筋截面的响应强度,从而弥补了Ghost模块丢失的空间位置和边界信息。

消融实验结果表明LPR-YOLO的轻量化和精度提升源于Ghost模块与CBAM模块的协同作用,二者缺一不可,单纯压缩或单纯引入注意力均无法达到最优。

3.5 对比实验与鲁棒性分析

为全面评估所提方法的性能优势,在自建的高密度钢筋截面数据集上同当前主流算法开展横向对比验证,实测结果汇总于表3。

根据实验结果可知,对比YOLOv5、YOLOv9、Faster R-CNN这三大主流模型,在mAP@0.5上分别提高了2.4%、1.1%。尽管模型精度仅有少量提

升,但在模型的参数量和计算量上却有十分显著的优化与减少,实验结果印证了LPR-YOLO在模型复杂度控制方面相对前沿方法的优势。Faster R-CNN虽然精度较高,然而这种微弱的精度领先是以极其庞大的计算代价换来的,其参数量是本文模型的25倍以上,计算量更是相差20倍,在实际业务过程中,这种庞大体积和极高的推理延迟无法满足现场实时盘点的工程需求。

在推理速度方面,如表3所示,LPR-YOLO在RTX4060上实现了127 FPS(帧每秒)的检测速度。由于Ghost模块和CBAM引入了少量的内存访问开销,对比原始YOLOv8n检测速度略有降低,但该速度仍远超实时检测所需的30FPS标准,证明了该模型在保证高效性的同时,完全满足实际工程部署的实时性要求。综上所述,模型在密集钢筋检测任务中拥有竞争力的同时,仍能够保持模型的轻量化,为末端设备的密集钢筋截面检测提供了一种新方法。

表3 主流模型对照验证实验

Table 3 Comparative experiments on advanced models

模型	参数量/ 10^6	GFLOPs	mAP@0.5/%	FPS
YOLOv5	7.02	15.9	92.4	157
Faster R-CNN	44.17	108.5	96.3	7
YOLOv8	3.0	8.1	92.6	142
YOLOv9	2.04	7.7	93.7	91
LPR-YOLO	1.71	5.1	94.8	127

在实际工业现场中,边缘计算设备往往受到摄像头硬件成本或传输带宽的限制,模型对低分辨率输入的适应能力是衡量其落地价值的重要指标。在不重新训练模型的前提下,测试了LPR-YOLO在不同输入尺寸(640×640 、 480×480 、 320×320)下的推理性能,实验结果具体如表4所示。

当输入分辨率下采样至 480×480 时,模型的mAP@0.5仍保持在92.3%,仅比标准分辨率下降了2.5%,表明LPR-YOLO有效应对了中等程度的图像压缩,满足大多数工业相机的采集需求。然

表 4 不同分辨率下模型精度测试

Table 4 Model accuracy testing at different resolutions

输入尺寸	mAP50/%	Precision/%	Recall/%
640×640	94.8	93.4	91.6
480×480	92.3	92.8	88.4
320×320	78.8	87.5	72.4

而,当分辨率进一步降低至 320×320 时,检测精度出现较明显下滑。这主要是由于钢筋截面属于小

目标,过低的分辨率导致钢筋纹理特征在卷积过程中丢失。综上所述,在实际部署中应保持输入分辨率不低于 480×480 ,以确保高精度的计数效果。

3.6 结果可视化对比

为了更直观地评估 LPR-YOLO 模型在实际效果上的提升,选取测试集在密集堆叠、光照不佳等多种复杂场景下的代表图像,并将其与基线模型 YOLOv8n 的检测结果进行可视化对比,结果如图 6 所示。

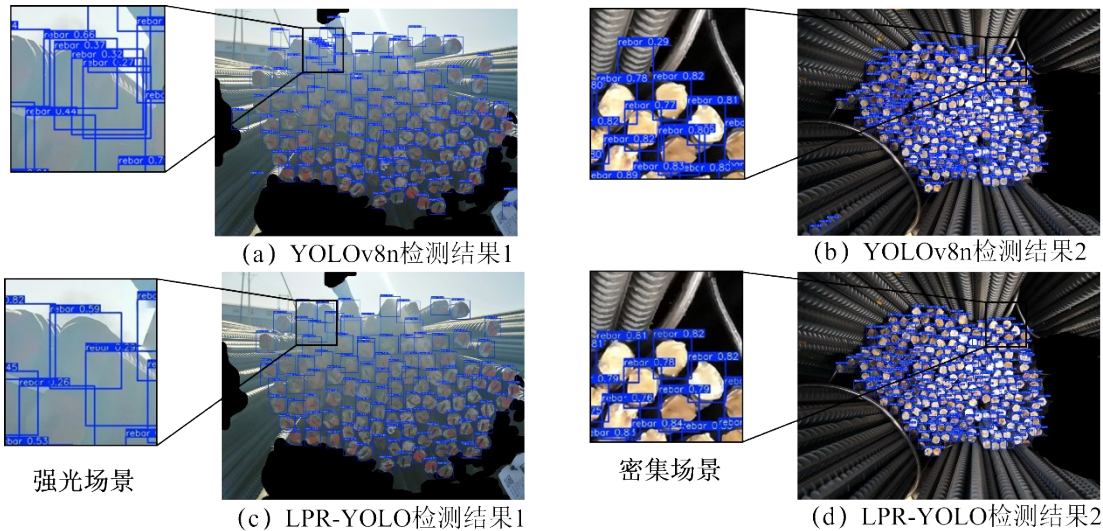


图 6 基线-改进模型对照实验

Fig.6 Baseline-Improved model comparison experiment

通过对比可知,在密集堆叠场景下原始 YOLOv8n 模型出现了明显的误检情况。由于钢筋之间的高度重叠,特征区分度降低,模型将钢筋间隙的阴影识别成钢筋截面。相较于基准模型,所提 LPR-YOLO 展现出更强的完整样本召回能力,有效规避漏检问题,Recall 指标显著改善。

而在光线干扰场景下,YOLOv8n 模型表现出不稳定性,不仅存在漏检还有多处误检。而 LPR-YOLO 模型准确定位到了处于强烈阳光下的钢筋截面,且没有产生误检,这证明 CBAM 模块有效地增强了模型对目标主体特征的关注,从而抑制了背景噪声的干扰。

为进一步深入探究 LPR-YOLO 模型在特征提取层面的内在机理,并直观验证 CBAM 模块对密集钢筋特征的聚焦能力,利用梯度加权类激活映射(Grad-CAM)热力图分析了模型推理过程中的关注区域。实验提取了颈部网络输出端、紧邻小目标检测头的 P3 层,对应特征尺度为 80×80 的特征图作为响应源。

可视化对比结果如图 7 所示,图中颜色越偏向红色代表模型对该区域的特征响应越强,表明它的

关注度越高;蓝色则代表低响应区域,即被抑制的背景。从图 7 可以看出,尽管引入 Ghost 模块削减了部分特征通道,但在 CBAM 模块的补偿下,LPR-YOLO 的热力图依然聚焦于钢筋截面中心(红色区域),且比原始 YOLOv8n 更干净地过滤掉了钢筋缝隙间的背景噪声。这证明 CBAM 模块有效补偿了 Ghost 模块在特征重构过程中可能产生的信息稀疏问题,确保了轻量化模型在密集场景下的特征聚焦能力。

Ghost 模块通过高效线性运算显著降低了计算




图 7 热力图对比

Fig.7 Heatmap comparison

量,但这种特征压缩可能会导致部分高频细节信息的丢失,尤其是在区分密集钢筋的边缘区域。为了补偿这一潜在的特征损失,CBAM模块的通道注意力机制(CAM)重新校准了剩余“内在特征”的权重,强化包含钢筋纹理的核心通道;而空间注意力机制(SAM)则在空间维度上抑制因特征压缩而引入的背景噪声。因此,Ghost模块提供了轻量化的结构基础,而CBAM模块提供了关键的特征导航,二者协同工作实现了参数量与检测精度的平衡。

综上所述,相较于基线模型YOLOv8n,提出的LPR-YOLO模型在应对密集、遮挡、光照变化和小目标等实际工程应用中的常见挑战时,其抗干扰能力与定位精度均得到显著提升。

3.7 成本效益对比

此外,与现有的自动化方案相比,基于计算机视觉的LPR-YOLO具有显著的成本效益优势。称重法虽然在宏观计量上效率较高,但由于钢筋生产中普遍存在的“负公差”现象,难以将重量精确转换为根数;RFID技术虽然能实现自动化追踪,但需要为每一根或每一捆钢筋配置电子标签,在大规模库存盘点中面临着标签耗材成本和粘贴人工成本的压力。相比之下,LPR-YOLO仅依赖通用的光学摄像头,无需额外耗材,且具备极高的部署灵活性,以最小的边际成本实现高精度的单根计数,具体成本与效益对比如表5所示。

表5 不同钢筋计数方法的成本与效益对比

Table 5 Cost-Benefit comparison of different rebar counting methods

方法	硬件成本	耗材成本	人工强度	计数精度
人工计数	无	无	非常高	低
称重法	高	无	低	中等
RFID射频识别	中	中等	高	高
LPR-YOLO	低	无	低	高

注:(注:表格内容参考文献[12,22]。)

4 结论

针对预制装配式梁厂成捆钢筋清点计数问题,提出了LPR-YOLO轻量化钢筋截面检测方法,得到以下主要结论:

1)提出了一种基于YOLOv8n的轻量化密集钢筋截面检测方法LPR-YOLO。该方法在主干网络中引入Ghost模块以降低参数量和计算复杂度,并在特征融合阶段加入CBAM注意力机制,以增强模型对关键目标区域的表征能力,从而兼顾检测精度与轻量化部署需求。

2)在自建的密集钢筋截面数据集上的实验结

果表明,LPR-YOLO取得了94.8%的mAP@0.5,较基线YOLOv8n提升了2.2%,同时参数量减少 1.3×10^6 、计算量减少了3GFLOPs。消融实验与可视化结果进一步验证了GhostNet与CBAM模块的协同作用,使模型在保持轻量化的同时显著提升了在密集堆叠、部分遮挡及光照变化等复杂场景下的鲁棒性和检测精度。

3)提出的LPR-YOLO模型在精度、速度与复杂度之间实现了更优平衡,为钢筋自动化清点技术在移动端及嵌入式设备上的实际部署提供了高效解决方案,满足了现代预制梁厂物料管理精细化与信息化的需求。未来研究可进一步聚焦于模型在实际硬件平台上的部署优化以及数据集多样性的持续扩展。

参考文献

- [1] 伊东波,张阔. 预制梁场智慧中枢驱动智能化生产研究[J]. 绿色建筑与智能建筑, 2025(8): 73-76.
Yi D B, Zhang K. Research on the intelligent production driven by the smart hub of prefabricated beam yard[J]. Green Construction and Intelligent Building, 2025(8): 73-76. (in Chinese)
- [2] 李长春,郝艳海. 智能化预制梁厂功能区布局及优化设计[J]. 建筑施工, 2023, 45(6): 1199-1202.
Li C C, Hao Y H. Functional area layout and optimization design of intelligent precast beam factory[J]. Building Construction, 2023, 45(6): 1199-1202. (in Chinese)
- [3] 刘天文. 建筑工程施工技术与现场施工管理[J]. 建材发展导向, 2025, 23(6): 97-99.
Liu T W. Construction technology and site construction management of building engineering[J]. Development Guide to Building Materials, 2025, 23(6): 97-99. (in Chinese)
- [4] Wang H, Polden J, Jirgens J, et al. Automatic rebar counting using image processing and machine learning [C]//2019 IEEE 9th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER). July 29-August 2, 2019. Suzhou, China. IEEE, 2019: 900-904.
- [5] 倪富陶,李倩,聂云靖,等. 基于改进YOLOv8的轻量化钢筋端面检测算法研究[J]. 太原理工大学学报, 2024, 55(4): 696-704.
Ni F T, Li Q, Nie Y J, et al. Lightweight rebar end detection algorithm based on improved YOLOv8[J]. Journal of Taiyuan University of Technology, 2024, 55(4): 696-704. (in Chinese)
- [6] 臧晶,刘冠楠,杨慧英. Otsu算法的打捆钢筋计数方法研究[J]. 沈阳理工大学学报, 2017, 36(6): 47-50, 60.
Zang J, Liu G N, Yang H Y. A method of counting

- packed steel bar based on Otsu algorithm[J]. Journal of Shenyang Ligong University, 2017, 36(6): 47-50, 60. (in Chinese)
- [7] 袁中锦, 刘宇, 时娟. 基于空间相关性的成捆钢筋图像计数算法研究[J]. 电脑与信息技术, 2019, 27(4): 10-13. Yuan Z J, Liu Y, Shi J. Research on counting algorithms of bundled steel bar image based on spatial-correlation[J]. Computer and Information Technology, 2019, 27(4): 10-13. (in Chinese)
- [8] 刘啸宇, 黄永, 徐峰, 等. 基于轻量化卷积神经网络的桥梁斜拉索 PE 护套损伤识别方法[J]. 土木与环境工程学报(中英文), 2025, 47(1): 167-178. Liu X Y, Huang Y, Xu F, et al. Damage identification method of PE sheath of bridge stay cable based on lightweight convolutional neural network[J]. Journal of Civil and Environmental Engineering, 2025, 47(1): 167-178. (in Chinese)
- [9] 姚刚, 廖港, 杨阳, 等. 基于卷积神经网络的预制叠合板多目标智能化检测方法[J]. 土木与环境工程学报(中英文), 2024, 46(1): 93-101. Yao G, Liao G, Yang Y, et al. Multi-target intelligent detection method of prefabricated laminated board based on convolutional neural network[J]. Journal of Civil and Environmental Engineering, 2024, 46(1): 93-101. (in Chinese)
- [10] 王超, 张运楚, 孙绍涵, 等. 改进 YOLOv5 算法的钢筋端面检测[J]. 计算机系统应用, 2022, 31(4): 68-80. Wang C, Zhang Y C, Sun S H, et al. Steel-bar end face detection based on improved YOLOv5 algorithm[J]. Computer Systems and Applications, 2022, 31(4): 68-80. (in Chinese)
- [11] Su Z Q, Fang K L, Peng Z T, et al. Rebar automatically counting on the product line[C]//2010 IEEE International Conference on Progress in Informatics and Computing. December 10-12, 2010, Shanghai, China. IEEE, 2010: 756-760.
- [12] 石京磊. 基于卷积神经网络的钢筋计数算法研究[D]. 武汉: 华中科技大学, 2019. Shi J L. Rebar counting algorithm research based on convolutional neural network[D]. Wuhan: Huazhong University of Science and Technology, 2019. (in Chinese)
- [13] Wang S, Kim M, Hae H, et al. The development of a rebar-counting model for reinforced concrete columns: using an unmanned aerial vehicle and deep-learning approach[J]. Journal of Construction Engineering and Management, 2023, 149(11): 04023111.
- [14] Sohan M, Sai Ram T, Rami Reddy C V. A review on YOLOv8 and its advancements[M]//Data Intelligence and Cognitive Informatics. Singapore Springer Nature Singapore, 2024: 529-545.
- [15] 翟永杰, 朱浩硕, 李佳蔚, 等. VDD-YOLO: 用于车辆变形损伤的评估方法[J]. 科学技术与工程, 2025, 25(29): 12560-12569. Zhai Y J, Zhu H S, Li J W, et al. VDD-YOLO: method for vehicle deformation and damage detection[J]. Science Technology and Engineering, 2025, 25(29): 12560-12569. (in Chinese)
- [16] 熊恩杰, 张荣芬, 刘宇红, 等. 面向交通标志的 Ghost-YOLOv8 检测算法[J]. 计算机工程与应用, 2023, 59(20): 200-207. Xiong E J, Zhang R F, Liu Y H, et al. Ghost-YOLOv8 detection algorithm for traffic signs[J]. Computer Engineering and Applications, 2023, 59(20): 200-207. (in Chinese)
- [17] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13-19, 2020. Seattle, WA, USA. IEEE, 2020: 1577-1586.
- [18] Hou H T, Guo M Z, Wang W, et al. Improved lightweight head detection based on GhostNet-SSD[J]. Neural Processing Letters, 2024, 56(2): 126.
- [19] Paoletti M E, Haut J M, Pereira N S, et al. Ghostnet for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(12): 10378-10393.
- [20] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Computer Vision - ECCV 2018. ChamSpringer International Publishing2018: 3-19.
- [21] Chen L J, Yao H D, Fu J Y, et al. The classification and localization of crack using lightweight convolutional neural network with CBAM[J]. Engineering Structures, 2023, 275: 115291.
- [22] 赵本省. 基于智能建造的装配式建筑施工关键技术研究与应用[D]. 郑州: 郑州大学, 2020. Zhao B S(X). Research and application of key technologies of prefabricated building construction based on intelligent construction[D]. Zhengzhou: Zhengzhou University, 2020. (in Chinese)