

基于改进 YOLOv8n 的室外车位检测算法

葛旭¹ 姜月秋¹
 GE Xu JIANG Yueqiu

摘要

针对目前室外车位检测算法存在参数量大和因室外环境多变而导致的检测效果差等问题, 文章提出了一种基于改进 YOLOv8n 的室外车位检测算法。针对模型参数量大和计算复杂的问题, 在主干网络中融入 RepGhostNet 轻量级网络, 减少计算量并提高模型的轻量化程度。同时针对室外停车场图像背景复杂和车位边缘信息特征不足的问题, 通过在颈部网络中嵌入卷积注意力模块 CBAM 来抑制背景信息干扰和强化车位特征。实验结果表明, 改进后模型 mAP 达到 96.0%, 参数量和计算量分别下降了 11% 和 12%, 在降低网络模型大小的同时也能够维持较高的检测精度和检测速率。

关键词

车位检测; YOLOv8n; RepGhostNet; CBAM; 室外停车场

doi: 10.3969/j.issn.1672-9528.2025.02.002

0 引言

随着城市化进程的加快, 城市人口基数不断攀升, 机动车数量迅速增长, 导致停车位供需矛盾日益突出, 尤其在一线城市, 停车难已成为常见问题。现有的基础设施和停车管理手段无法有效应对这一挑战, 迫切需要智能化的停车管理系统。基于深度学习车位检测技术凭借其高效性和准确性, 成为解决停车问题的重要方向。

为了解决停车位供需矛盾, 提升停车管理效率, 越来越多的研究者开始探索基于深度学习车位检测技术。该技术通过高效的目标检测算法, 实时获取和分析车位信息, 有效提高了车位利用率。在此背景下, 众多改进方案应运而生。杨飞帆等人^[1]改进 YOLOv8 用于环视车位检测, 设计了 Faster Block 替换 C3 与 C2f 模块, 并加入 CoordAtt 注意力层。Yuldashev 等人^[2]通过改进 MobileNetV3, 优化车位占用检测的模型结构和特征提取过程。唐玉良等人^[3]改进 YOLOv7-tiny, 增加车位关键点回归分支并结合注意力机制, 提升车位区域与使用状态检测。韩瑞东等人^[4]提出利用霍夫变换精确定位停车区域边界, 结合 CNN 分类空闲车位。李玥等人^[5]改进 YOLOv5m, 增加小目标检测层, 结合坐标注意力机制, 减少冗余信息, 提升小车位的检测效果。

尽管基于深度学习车位检测技术取得了显著进展, 但在复杂的室外环境中, 传统模型的计算复杂度较高, 背景干扰和车位特征提取效果仍有待提升。尤其是在应对动态光照条件、遮挡物等因素时, 现有方法的鲁棒性和检测精度受到影响。因此本文提出了一种基于改进 YOLOv8n 的室外车位

检测算法, 旨在降低网络模型大小的同时也能够维持较高的检测精度和检测速率。

1 YOLOv8 模型结构

YOLO 算法^[6]的主要思想是通过一个单一的卷积神经网络直接预测边界框和类标签。YOLO 通过将整个图像划分为多个网格, 且每个网格负责检测图像中物体的存在与否, 从而实现了端到端的处理。YOLOv8^[7]继续沿用这一思想, 并进一步优化模型架构。采用更为高效的骨干网络, 结合新型的特征融合技术, 增强对不同尺度目标的检测能力。

YOLOv8 的模型结构如图 1 所示, Input 层负责将待检测的图像输入到网络中。

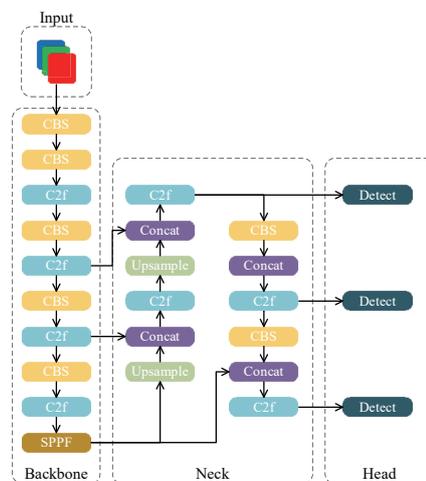


图 1 YOLOv8 结构图

先由 Backbone 层进行特征提取, Backbone 层由若干卷积-批量归一化-激活函数 (CBS) 组合和 C2f 等残差结构构成, 可以有效提取图像不同尺度的特征。再由 Neck 层处理和融

1. 沈阳理工大学信息科学与工程学院 辽宁沈阳 110159

合来自 Backbone 层的特征图, Neck 层利用上采样 (Upsample) 和拼接 (Concat) 技术, 结合 SPPF 模块对输入的特征层进行池化操作将不同层级的特征进行融合, 进一步增强多尺度特征融合和上下文信息提取的能力。最后由 Head 层将 Neck 层的输出特征图转换为检测结果, Head 层采用解耦头设计将回归分支和预测分支分离以进行边框回归和目标分类任务。

2 基于改进 YOLOv8n 的室外车位检测

YOLOv8 基于缩放系数提供了不同尺度的模型, 以满足不同部署平台和应用场景的需求。基于车位检测应用场景, 本文选择以 YOLOv8n 为基础进行车位检测算法研究。虽然 YOLOv8n 模型在车位检测方面表现出色, 但是部署到室外场景边缘端设备上, 仍存在计算量大、检测精度低、推理速度慢等问题。为了解决这些问题, 本文针对 YOLOv8n 网络结构进行了改进。

2.1 RepGhostNet

GhostNet^[8] 是华为诺亚方舟实验室在 2020 年开发的一个轻量级网络, 旨在压缩网络并简化模型, 同时确保模型具有一定的精确度, 被广泛用于轻量化网络设计。

Ghost 模块通过生成廉价的幽灵特征图并使用 Concat 操作进行融合, 减少了冗余计算, 大大降低了模型的复杂度。RepGhost^[9] 模块在此基础上进一步优化, 采用 Add 操作替代 Concat 操作, 使得信息融合更加高效。此外, 借助重参数化技术, RepGhost 在推理阶段将多分支结构简化为单一卷积层, 大幅提升推理速度, 同时通过加入 BN 层提升了模型的精度。

如图 2 所示, 基于 Ghost 和 RepGhost 模块, 提出了针对轻量化网络的 G-bneck (RepGhost bottleneck) 和 RG-bneck (RepGhost bottleneck) 模块。

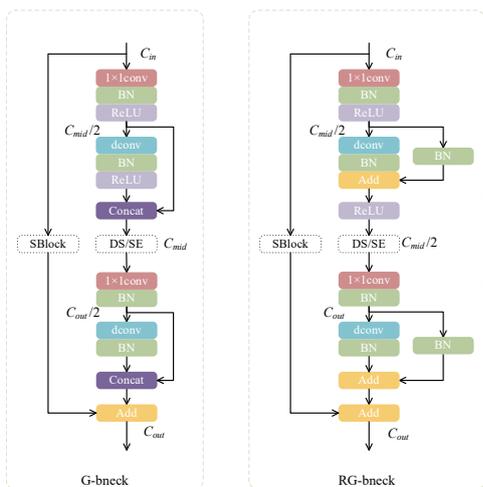


图 2 G-bneck 和 RG-bneck 结构图

G-bneck 结构和 RG-bneck 结构在设计上都融合了轻量化的思想, 并对通道和特征进行了优化处理。RG-bneck 结构通过 1×1 卷积和 ReLU 激活函数实现输入通道数量的减半, 接

着经过第一个 RepGhost 模块保持通道数不变, 然后经过 SE 通道注意力机制和 1×1 卷积, 提升模型对通道特征的敏感性, 并使输出通道与输入通道对齐。最后, 特征与初始输入特征图进行尺度相加操作, 并输出结果。

2.2 RG-C2f 模块

YOLOv8 主干网络中的 C2f 模块在处理多通道特征时存在较大的计算量, 对于运算性能有限的边缘端设备是一种限制。而 RG-bneck 模块首先在重参数化过程优化推理时的卷积计算量, 能够降低对硬件的依赖。其次结合深度瓶颈结构和多尺度特征融合, 在面对复杂环境或细节特征时表现出更好的检测精度, 同时显著减少参数量和模型大小。而且在保留轻量化的同时, 通过添加 SE 通道注意力机制, 增强了对通道特征的敏感性, 从而提高模型的代表能力。

因此本文设计了 RG-C2f 模块, 如图 3 所示。该模块将原特征提取网络 C2f 模块中的 Bottleneck 模块替换为 RG-bneck 模块, 使得改进后的网络更加轻量化。该模块通过特征图的有效重用, 优化了串联运算器结构, 从而在降低资源消耗的同时减少了模型推理过程中的计算复杂度, 显著提高了模型在实际应用中的效率。同时结合 C2f 模块的多层次特征融合机制, RG-C2f 能够更好地整合不同层次的特征, 从而增强模型在不同尺度目标上的检测能力, 特别是在复杂场景下有明显优势。

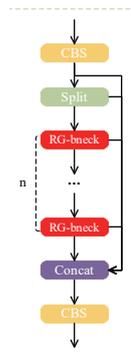


图 3 RG-C2f 模块图

2.3 CBAM 注意力机制

CBAM^[10] 是一种用于神经网络的轻量级注意力机制, 由通道注意力模块和空间注意力模块组成。两个模块分别对特征图的通道和空间维度进行加权, 从而增强网络对重要特征的关注能力。其结构图如图 4 所示。

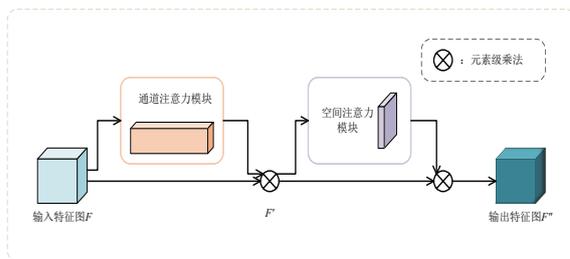


图 4 CBAM 结构图

其中通道注意力机制模块具体流程为: 设输入的特征图为 $F \in \mathbf{R}^{H \times W \times C}$ 。对输入特征图进行池化操作, 从而得到两个全局描述向量 $F_{avg} \in \mathbf{R}^{1 \times 1 \times C}$ 和 $F_{max} \in \mathbf{R}^{1 \times 1 \times C}$ 。将 F_{avg} 和 F_{max} 分别通过一个共享的多层感知器 MLP (multi-layer perceptron), 得到两个经过非线性激活的输出 M_{avg} 和 M_{max} 。将 M_{avg} 和 M_{max} 相加, 并通过 Sigmoid 激活函数生成通道注意力图 M_c 。

将输入特征图 F 与通道注意力图 M_c 相乘，得到加权后的特征图 F' 。这样，重要的通道会被增强，不重要的通道则会被抑制。计算公式分别为：

$$M_{avg} = W_1(\text{ReLU}(W_0 F_{avg})) \quad (1)$$

$$M_{max} = W_1(\text{ReLU}(W_0 F_{max})) \quad (2)$$

$$M_c = \sigma(M_{avg} + M_{max}) \quad (3)$$

$$F' = M_c \cdot F \quad (4)$$

空间注意力模块具体流程为：设输入的特征图 $F' \in \mathbf{R}^{H \times W \times C}$ ，这是经过通道注意力模块处理后的特征图。对 F' 进行通道维度的全局池化，生成两个二维空间描述特征图 F'_{avg} 和 F'_{max} 。将 F'_{avg} 和 F'_{max} 在通道维度上进行拼接，并通过一个 7×7 的卷积核进行卷积，生成空间注意力图 M_s 。将空间注意力图 M_s 与输入特征图 F' 相乘，得到加权后的输出特征图 F'' ，增强了特征图中空间维度上重要的区域，使得模型更关注于有用的空间信息。计算公式分别为：

$$M_s = \sigma(\text{Conv}([F'_{avg}; F'_{max}])) \quad (5)$$

$$F'' = M_s \cdot F' \quad (6)$$

本文将 CBAM 模块添加到 PAN-FPN 结构中下采样阶段的每个 C2f 模块后。这有助于强化网络对细粒度特征的提取。也增强了模型对不同尺寸目标的敏感性。同时也能避免因下采样导致的细节损失，从而提升检测精度。添加 CBAM 模块后的网络结构图如图 5 所示。

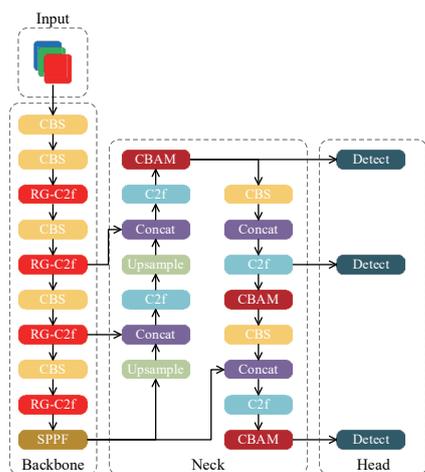


图 5 改进后的 YOLOv8 结构图

3 实验

3.1 实验环境

本文针对模型训练的实验平台配置如下：CPU 型号为 Intel i7-10700KF、搭载 2 张 A5000 24 GB 显卡、深度学习框架采用 Python3.8.17、PyTorch2.0.0 和 CUDA11.3 版本、操作系统为 ubuntu20.04。输入图片尺寸为 $640 \text{ px} \times 640 \text{ px}$ ，训练轮数为 300，批处理大小为 16，初始学习率为 0.01。

3.2 实验数据集

本文实验采用 PASCAL VOC (visual object classes) 数据集，从中选取不同环境下总共 2492 张包含空车位和非空车位的停车场图片，按照 8:1:1 的比例划分训练集、测试集和验证集。

3.3 评价指标

采用平均精度均值 (mAP)、浮点运算次数 (GFLOPs)、参数量 (Params) 3 个指标来衡量模型性能。

3.4 对比实验

针对改进后模型的性能评估，本小节进行了改进后 YOLOv8n 模型与主流的一阶段和两阶段目标检测算法的对比实验，实验结果如表 1 所示。

表 1 对比实验结果

Model	mAP@0.5/%	GFLOPs	Params/ 10^6
Faster RCNN	85.6	369.8	136.73
SSD	79.9	360.9	50.21
YOLOv3	92.0	282.2	103.67
YOLOv3-tiny	94.1	18.9	12.13
YOLOv5n	84.3	7.1	2.50
YOLOv6n	84.6	11.8	4.23
YOLOv7-tiny	55.0	13.2	6.02
YOLOv8n	86.1	8.1	3.01
Ours	96.0	7.1	2.68

改进后的模型比原 YOLOv8n 和其他一阶段及两阶段模型有显著的精度提升。这表明模型在处理各种不同复杂度的检测任务时，能够更加准确地识别和定位目标，特别是在复杂场景或细粒度目标检测中，效果明显优于其他模型。

在大幅提升精度的同时，改进后的模型仍保持了出色的轻量化性能，参数量仅为 2.68×10^6 ，计算复杂度也控制在 7.1 GFLOPs，比大多数同类模型更高效，适合在低功耗、高效率的设备上进行实时部署。

3.5 消融实验

为验证本章对 YOLOv8n 算法模型改进方法的优化作用，本小节以 YOLOv8n 为基准对改进后的模型进行了消融实验以及性能分析，实验结果如表 2 所示。

表 2 消融实验结果

实验	mAP@0.5/%	GFLOPs	Params/ 10^6
1	86.1	8.1	3.01
2	95.2	7.0	2.60
3	86.2	8.2	3.09
4	96.0	7.1	2.68

实验 1 为原始的 YOLOv8n 模型；实验 2 为只改进 RG-

C2f 模块后的模型；实验 3 为只融入 CBAM 注意力机制的模型；实验 4 为既改进 RG-C2f 模块又融入 CBAM 注意力机制的模型。

将 YOLOv8n 中的 Backbone 部分的 C2f 模块替换为结合 RG-bneck 的 RG-C2f 模块后，模型精度大幅提升。mAP@0.5 上升至 95.2%。同时，参数量减少至 2.60×10^6 ，GFLOPs 降低至 7.0，这表明 RG-C2f 模块不仅提升了模型的精度，还在一定程度上降低了计算量，提升了推理效率。这一改进对模型的整体性能有显著的优化。

在 YOLOv8 的 Neck 部分的下采样 C2f 模块中加入 CBAM 注意力机制后，模型的精度稍有提升，mAP@0.5 上升至 86.2%，略高于基础模型。GFLOPs 上升至 8.2，参数量增加至 3.09×10^6 。虽然精度提升不如 RG-C2f 显著，但 CBAM 能有效改善模型的细节处理能力。

当同时引入 RG-C2f 模块和 CBAM 注意力机制时，模型的精度达到了实验中的最佳水平。mAP@0.5 提升至 96.0%。这表明两者的结合在特征提取和特征融合方面产生了协同作用：RG-C2f 模块通过高效的特征表示增强了 Backbone 部分的特征提取能力，而 CBAM 进一步提高了 Neck 部分特征融合的有效性，使得模型在多尺度物体检测和复杂场景下均能保持较高的检测精度。此外，尽管增加了注意力机制，整体计算量仅增加至 7.1 GFLOPs，参数量为 2.68×10^6 ，仍保持了较低的复杂度。因此，RG-C2f 和 CBAM 的结合在性能与复杂度之间达到了良好的平衡。

4 结论

针对目前室外车位检测算法存在参数量大和因室外环境多变而导致的检测效果差等问题，提出了一种改进 YOLOv8n 的室外车位检测算法。通过引入 RG-C2f 模块和 CBAM 注意力机制，显著提升了车位检测任务中的精度，同时有效控制了模型的复杂度。RG-C2f 模块在提升特征提取能力的同时，通过 Ghost 卷积减少了不必要的计算冗余，优化了推理效率。在此基础上，CBAM 注意力机制通过增强模型对重要特征区域的关注，进一步提升了检测性能，尤其在复杂场景下的表现尤为突出。改进后的 Ours 模型在 mAP@0.5 上达到 96.0%，相比 YOLOv8n 提升了 9.9%，并且 GFLOPs 和参数量分别下降至 7.1 和 2.68×10^6 ，进一步降低了模型的计算复杂度。通过该优化策略，改进后的模型在保持轻量化的同时，实现了卓越的检测精度和推理速度，适用于实际应用中的室外车位检测任务，尤其在实时性要求较高的场景下具备广泛的应用潜力。

参考文献：

- [1] 杨飞帆, 李军, 王耀弘. 改进 YOLOv8 的环视车位检测算法研究 [J]. 重庆理工大学学报 (自然科学), 2024, 38(9): 22-29.
- [2] YULDASHEV Y, MUKHIDDINOV M, ABDUSALOMOV B A, et al. Correction: yuldashev et al. parking lot occupancy detection with improved MobileNetV3. sensors 2023, 23, 7642 [J]. Computer vision for smart cities, 2024, 24(16): 5236.
- [3] 唐玉良, 张轩雄. 基于深度学习的车位检测方法 [J/OL]. 电子科技, 1-9 [2024-07-23]. <https://doi.org/10.16180/j.cnki.issn1007-7820.2025.06.004>.
- [4] 韩瑞东, 杨攀. 停车场车位识别算法研究 [J]. 运城学院学报, 2024, 42(3): 31-36.
- [5] 李玥, 马世典, 黄宇轩. 基于改进 YOLOv5m 的室内停车位检测 [J]. 软件导刊, 2024, 23(4): 157-163.
- [6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 779-788.
- [7] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. 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.
- [8] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations [C/OL] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020 [2024-04-26]. <https://ieeexplore.ieee.org/document/9157333>.
- [9] CHEN C P, GUO Z C, ZENG H E, et al. RepGhost: a hardware-efficient ghost module via Re-Parameterization [DB/OL]. (2024-07-31) [2024-08-11]. <https://doi.org/10.48550/arXiv.2211.06088>.
- [10] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [DB/OL]. (2018-07-18) [2024-04-13]. <https://doi.org/10.48550/arXiv.1807.06521>.

【作者简介】

葛旭 (1999—), 男, 河北邯郸人, 硕士研究生, 研究方向: 目标检测。

姜月秋 (1975—), 通信作者 (email: yueqiujiang@syju.edu.cn), 女, 山东莱州人, 博士, 教授, 研究方向: 深度学习、网络传输。

(收稿日期: 2024-10-24)