光电技术及应用

DOI：10.16818/j.issn1001－5868.2024072602

基于 LCD-YOLO 的车辆检测算法

代少升[1]，代佳伶[1]，余自安[2*]

（1. 重庆邮电大学 通信与信息工程学院，重庆 400065；2. 昆明云内动力股份有限公司，昆明 650200）

摘　要： 针对现有 YOLOv8s 车辆检测模型的检测精度低、参数量多、计算量大的问题，提出了一种基于改进 YOLOv8s 的 LCD-YOLO 轻量化车辆目标检测算法。该算法使用频率自适应膨胀卷积优化 YOLOv8s 中的 C2f 模块，以提升特征融合能力；使用共享卷积层，减少网络卷积次数，以此减少参数量来实现模型轻量化；通过动态聚焦的边界框回归损失计算方法，能够有效增强网络对遮挡重叠目标检测能力，提高边框检测精度。在 KITTI 数据集上进行实验，结果表明所提算法平均检测精度提升到 95.1%，相比于 YOLOv8s 算法检测精度提高了 2.9%，网络参数量减少 14.9%，计算量减少 10.9%，能更好满足车辆的实际检测需求。

关键词： 车辆检测；YOLOv8s；特征融合；轻量化

中图分类号： TP391　**文章编号：** 1001－5868(2024)06－1039－08

Research on Vehicle Detection Algorithm Based on Lightweight Car Detection-YOLO

DAI Shaosheng[1], DAI Jialing[1], YU Zian[2]

(1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, CHN; 2. Kunming Yunnei Power Co., Ltd., Kunming 650200, CHN)

Abstract: To address the issues of the low detection accuracy, exorbitant number of parameters, and extensive computations in the existing YOLOv8s vehicle detection model, a lightweight car detection-YOLO (LCD-YOLO) algorithm based on improved YOLOv8s is proposed for lightweight vehicle target detection. The algorithm applies frequency-adaptive dilated convolution (FADC) to optimize the cross-range partial (CSP) bottleneck with two convolutions (C2f) in YOLOv8s to enhance feature fusion ability. Shared convolutional layers reduce the number of network convolutions and parameters, thereby achieving a lightweight model. Through the dynamic focusing of the bounding box regression loss calculation method, this model can effectively improve the network's ability to detect occluded overlapping targets and improve the accuracy of border detection. Experiments on the KITTI dataset show that the average detection accuracy of the proposed algorithm is improved to 95.1%, which is 2.9% higher than that of the YOLOv8s algorithm, while reducing the number of network parameters by 14.9% and amount of computation by 10.9%, which can better satisfy the actual detection needs of vehicles.

Key words: vehicle detection; YOLOv8s; feature fusion; lightweight

收稿日期：2024－07－26.

*通信作者：余自安

0 引言

车辆检测是先进辅助驾驶系统的重要研究内容之一。然而行车道路具有环境复杂性、路况不确定性等特点，这对车辆检测是一项巨大的挑战；与此同时车辆检测需要大量的计算资源和存储空间。因此，如何在改善车辆检测精度的同时，有效降低计算量、减小模型大小成为热门研究方向。

车辆检测技术经历了三个主要的发展阶段：传统特征设计、机器学习以及深度学习。早期，传统方法通过 Haar[1] 和 HOG[2] 等技术手动提取车辆的颜色、纹理和形状等特征进行识别，但这些方法依赖于预设特征，不仅耗时耗力，在复杂环境中难以设计有效特征，而且泛化能力有限，需要针对不同环境重新设计特征。随着技术的进步，机器学习和深度学习使得模型能够自动从大量数据中学习特征，无需人工干预，这不仅提高了检测效果，还更好地反映了数据的内在分布。在深度学习领域，车辆目标检测的主流算法主要分为两种：二阶段和一阶段。二阶段算法，如 R-CNN[3-5] 系列，通过候选区域生成器提取候选区域，然后进行分类，虽然准确度高，但速度较慢，不适合实时性要求高的场景；一阶段算法，例如 YOLO 系列[6-12] 和 SSD[13]，通过卷积神经网络直接在图像上生成边界框并进行分类，速度较快但精度相对较低。

近年来，许多学者致力于研究轻量级网络和车辆目标检测的结合。例如，郭宇阳等[14] 提出了一种基于 YOLOv4 和 GhostNet 的轻量化模型，通过改进网络结构和注意力机制，以及使用 FireModule 和深度可分离卷积，实现了模型的优化和精确度的提升。Li 等[15] 优化 YOLOv5 网络，通过引入环形平滑标签分类方法，在主干网络级联 Swin Transformer 和自适应空间特征融合结构，显著提升了无人机图像中小尺寸旋转车辆的检测精度和实时性，具有低参数量和高帧率的优势。Wu 等[16] 则基于 YOLOv7-tiny 模型，通过引入新的网络结构和激活函数，增强了模型的泛化能力。

尽管上述研究在速度和精度上取得了进步，但对于实际场景下的车辆检测来说，网络模型依然较大，且大多数模型在轻量化和检测精度上难以达到有效平衡。本文提出了一种轻量级网络模型 LCD-YOLO（Lightweight Car Detection-YOLO），该模型在降低模型参数计数和计算负载的同时，保持了较高的检测精度。

1 YOLOv8s 网络

YOLOv8s 在 YOLOv5 的基础上进行了改进，并融入了 YOLOv7 的 ELAN 算法理念。与之前的 YOLO 模型相比，YOLOv8s 在检测性能上有了显著提升。

YOLOv8s 的网络结构如图 1 所示，主要由 Backbone，Neck 和 Head 三部分组成。Backbone 层用于从图像中提取特征，其中 Conv 用于特征提取、C2f（CSP Bottleneck with 2 Convolutions）结构用于实现轻量化并丰富梯度信息学习、SPPF 模块有助于处理不同尺寸的目标；Neck 层用于对特征进行整合，由一系列卷积层和上采样组成；Head 层负责根据特征生成预测结果。

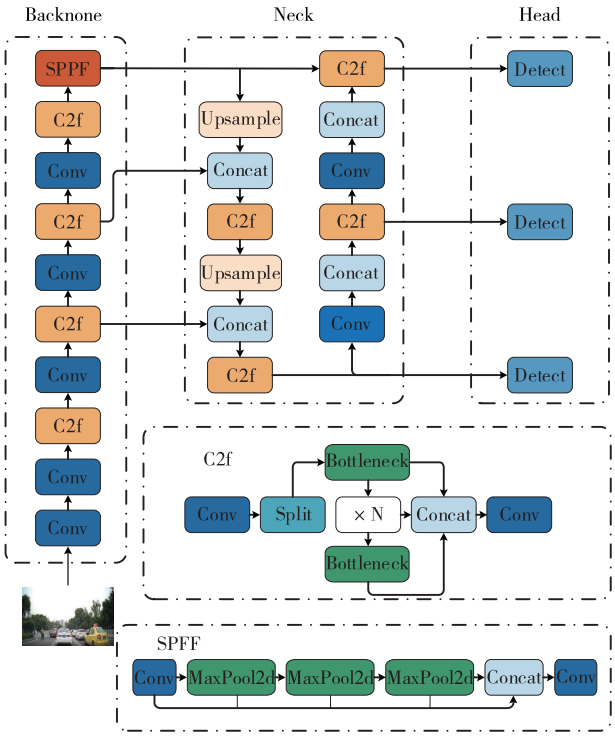


图 1 YOLOv8s 网络结构图

2 改进 YOLOv8s 算法

虽然 YOLOv8s 网络在目标识别精度上有较好的性能，但在复杂路况环境下，车辆存在被遮挡、车辆尺寸大小不一的问题，导致对车辆的识别精度不高。此外，网络参数量过多、计算量大，难以应用到实际场景。为此，本文在 YOLOv8s 模型的基础上，进行了针对性的轻量化设计，以保持识别的准确性，并对网络结构进行了优化。

图 2 展示了基于 YOLOv8s 的 LCD-YOLO 模型结构。该算法使用频率自适应膨胀卷积(Frequency-Adaptive Dilated Convolution，FADC)模块替换了部分 C2f 的 BottleNeck 结构，增强网络的学习能力，以提升特征融合能力。为了在轻量化的同时保持精度，提出了共享卷积技术，并在网络的 Head 层引入了组归一化(Group Normalization，GN)模块提升模型的泛化能力。最后引入了 Wise-IoU 以进一步提高网络的推理速度和边界回归的准确性。

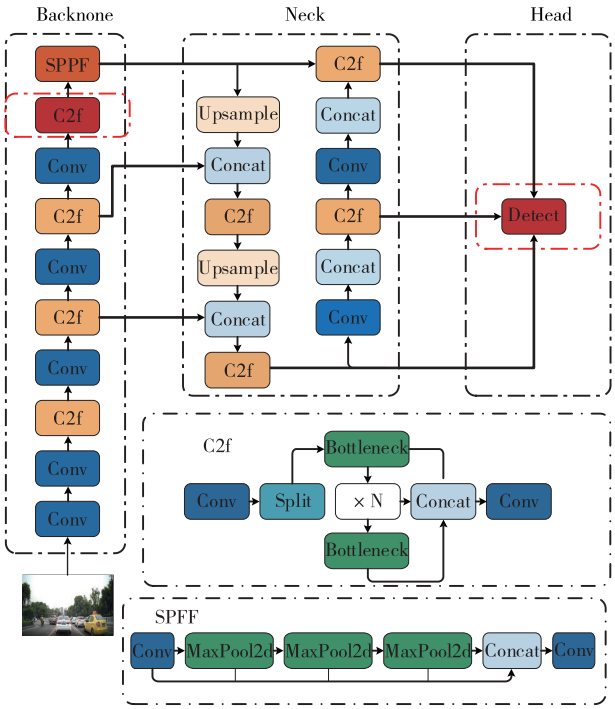


图 2　改进 LCD-YOLO 结构图

改进后的网络模型在确保车辆识别准确率的同时，实现轻量化并提高算法的实时性，满足复杂道路环境下的应用需求。

2.1　C2f 模块改进

在 YOLOv8s 的目标检测框架中，包含大量 C2f 模块，用于特征提取和增强。因此，网络性能的优劣与 C2f 模块特征学习的情况密切相关。

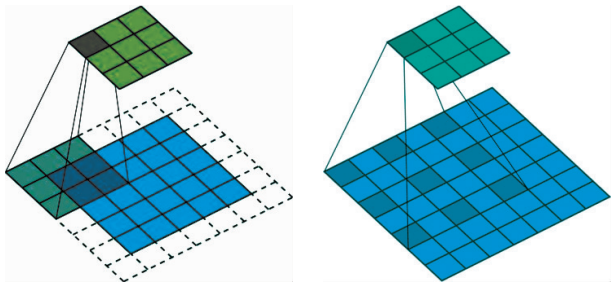
在复杂的道路环境下，车辆被遮挡或者以不同的角度出现，模型需要处理不同尺寸的车辆，原有的 C2f 模块对行驶条件下的车辆特征提取能力存在不足，缺少多尺度的特征信息。所以，为了进一步增强网络的学习能力，融合多尺度的特征信息，设计了一个全新的 C2f-FADC 模块。该模块将原 C2f 中的 Bottleneck 替换为 Bottleneck_FADC 模块，在原 Bottleneck 模块的基础上将原有的卷积替换为 FADC[17]，FADC 基于局部频率分量在空间上动态调整膨胀率，能更好地提取车辆特征。

膨胀卷积是通过在连续元素之间插入间隙来扩展感受野，在计算机视觉中得到了广泛应用。膨胀卷积可以表述为：

$$Y(p)=\sum_{i=1}^{K\times K}W_i X(p+\Delta p_i\times D) \tag{1}$$

式中，$Y(p)$表示输出特征图中 p 位置的像素值，K 是核大小，W_i 表示核的权重参数，$X(p+\Delta p_i)$表示输入特征图 Δp 中偏移对应位置的像素值，变量 Δp_i 表示预定义网格采样的第 i 个位置。

膨胀卷积的卷积核是在普通卷积核的基础上扩大了尺寸，真正参与运算的卷积核单元没有变化。感受野可以通过增加扩张率 D 来扩大。如图 3 为膨胀卷积与普通卷积的对比。



(a) 普通卷积　　(b) 膨胀卷积

图 3　卷积对比

FADC 脱离传统膨胀卷积的固定全局膨胀率作为超参数的做法，它基于局部频率分量在空间上动态调整膨胀率。如图 4 和图 5 为 FADC 的结构图，该结构由自适应膨胀率(AdaDR)、自适应卷积核(AdaKern)和频率选择(FreqSelect)构成。AdaDR 动态调整膨胀率，实现有效带宽和感受野之间的平衡；AdaKern 自适应地调整卷积核，以充分利用带宽；FreqSelect 学习频率平衡特征，以增大感受野。

(1) AdaDR

考虑到输入特征图在空间上的差异，每个位置的最佳膨胀率可能不同，FADC 引入了 AdaDR 策略来实现更好的平衡。AdaDR 根据输入特征的频谱动态调整膨胀率，为每个位置分配不同的膨胀率。在车辆检测中，高频区域(如车牌字符、车灯、车型标志和轮廓边缘)使用较小的膨胀率，以捕捉更多细节；低频区域(如车辆的整体形状、大面积车身和背景环境)使用较大的膨胀率，以扩大感受野，获取全局信息。这样，FADC 可以在各种复杂环境下有效

地识别不同大小和细节的车辆。表达式为：

$$Y(p)=\sum_{i=1}^{K\times K}W_i X(p+\Delta p_i\times \hat{D}(p)) \tag{2}$$

式中，$\hat{D}(p)$可通过一个参数为θ的卷积层来预测。

$$\theta=\max_{\theta}\Big(\sum_{p\in HP^-}\hat{D}(p)-\sum_{p\in HP^+}\hat{D}(p)\Big) \tag{3}$$

式中，HP^+和HP^-分别表示具有最高和最低高频功率的像素。

高膨胀率可能导致混叠现象，影响小目标的检测。FADC通过自适应调整膨胀率减少混叠现象，提高检测精度。与此同时，车辆识别需要处理不同尺寸的车辆，AdaDR能够捕捉从小型自行车到大型卡车的各种尺度特征。

(2)AdaKern

FADC将卷积核分解为低频和高频成分，并根据输入特征动态调整这些成分的比例，增强卷积核的频率响应。

AdaKern的权值表示如下：

$$W=\lambda_1\overline{W}+\lambda_h\hat{W} \tag{4}$$

式中，$\overline{W}=\frac{1}{K\times K}\sum_{i=1}^{K\times K}W_i$表示按卷积核计算的平均$W$；$\lambda_1$和$\lambda_h$是每个通道的动态权值，这个权值是由一个简单而轻量级的全局池化和卷积层来预测的。根据输入上下文动态调整λ_1/λ_h的比例，使网络能够专注于特定的频带，并适应特征中视觉模式的复杂性。这种动态频率自适应方法增强了网络捕获低频上下文和高频局部细节的能力，而车辆的特征细节(如车牌、车灯、车型标志)对于车辆检测至关重要，FADC通过增强高频响应来帮助网络更好地识别这些细节。

(3)FreqSelect

通过调整输入特征的频率功率分布，平衡频率响应，促进感受野的扩展。表达式为：

$$\hat{X}(i,j)=\sum_{b=0}^{B-1}A_b(i,j)X_b(i,j) \tag{5}$$

式中，$\hat{X}(i,j)$为频率选择后学习到的频率特征，$A_b\in\mathbb{R}^{H\times W}$为第$b$个频带的选择映射。这样的设计允许不同频率的特征进行融合，提供更丰富的特征表示。

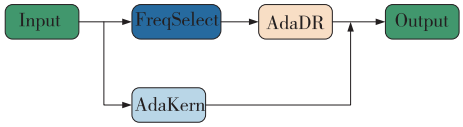


图4 FADC结构图

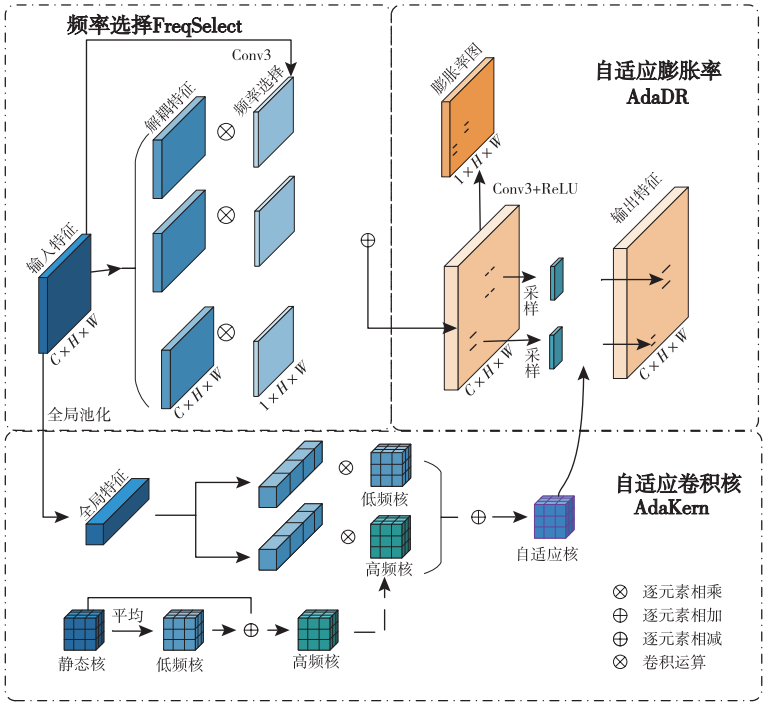


图5 FADC结构

总之，FADC通过其自适应膨胀率、自适应卷积核和频率选择机制，为车辆识别任务提供了一种强大的工具，能够在各种条件下提高识别的准确性和鲁棒性。

2.2　网络检测头重设计

原 YOLOv8s 的检测头结构如图 6 所示，分别通过两个 3×3 的卷积和一个 1×1 的卷积来提取信息，最后分别计算识别和分类的损失。

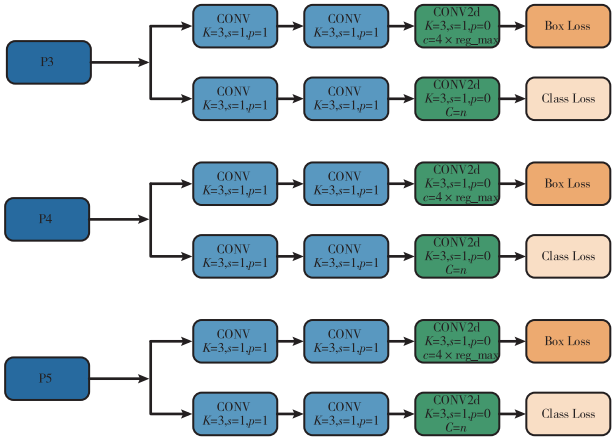


图 6　YOLOv8s 检测头结构图

YOLOv8s 的检测头是实现目标检测的核心部分，占据了整个模型计算量的大约五分之一。因此，通过改进 YOLOv8s 的检测头，可以在不显著降低精度的情况下减少模型的计算量。提出了一种新的检测头 LSH(Lightweight Share Head)设计，可以在最小化精度损失的同时减少参数量。具体改进措施如下：

(1)卷积层共享：传统检测头在每个检测层使用独立的卷积层进行特征处理，这导致了较高的计算成本。本文通过在多个检测层之间共享卷积层，显著减少了卷积操作的次数，从而降低了计算量。该设计特别适合计算资源受限的设备，有利于模型在实际场景下的部署。共享卷积层还减少了模型参数的数量，这不仅减少了模型的存储需求，还降低了过拟合的风险，增强了模型的泛化能力。在共享卷积层的情况下，模型能够在不同尺度的特征图上共享权重，有助于学习到更通用的特征。

(2)GN 的应用：在原有的卷积中添加了 GN，已有文献[16]证实了 GN 可以提升检测头在定位和分类方面的性能。与批量归一化(Batch Normalization，BN)不同，GN 在每个特征组内进行归一化，不依赖于批量大小。这种特性使得模型在小批量训练和分布式训练中更加稳定和鲁棒。因此 LSH 在卷积结构中使用 GN，GN 的引入提高了模型的泛化能力，减少了训练过程中的波动，有助于获得更高的检测精度。

(3)Scale 层的引入：为解决不同检测头所检测目标尺度不一致的问题，添加了 Scale 层，为每个检测头引入了可学习的缩放因子。Scale 层通过自适应调整特征图，使模型能够更有效地处理不同尺度的目标。缩放因子是可学习的，模型在训练过程中能够自动调整每个检测头的输出特征，从而提高对不同尺度目标的检测精度。

通过上述检测头的改进，不仅提高了模型的计算效率，还增强了模型对不同尺度目标的检测能力，改进后的检测头结构如图 7 所示。

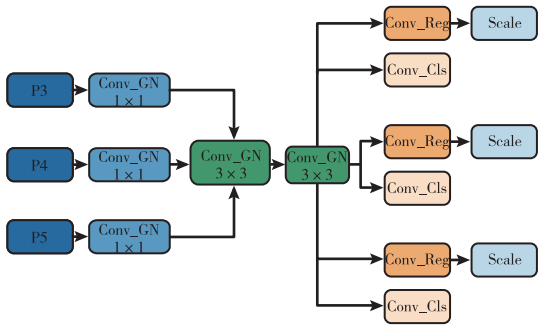


图 7　改进轻量化共享检测头结构图

2.3　IoU 损失函数的改进

在 YOLOv8s 模型中使用 CIoU 作为检测框回归损失函数。CIoU 损失函数是根据预测框和真实框的宽高比进行计算的，而不是简单地基于它们的宽高尺寸。当两者的宽高比一样时，CIoU 的结果会相同。然而，在实际目标检测应用中，物体的尺度可能会出现较大变化，尤其是在小目标检测中，样本可能受到环境因素的影响，如光照条件、遮挡、视角变化等，这些因素可能导致目标的尺寸、形状和外观发生较大变化，但 CIoU 无法有效地捕捉到这种变化，从而导致检测性能下降。

为解决以上局限性，引用 WIoU 作为检测框回归损失函数。WIoU 通过聚焦系数的计算方法添加了聚焦机制，实现了动态聚焦的边界框回归损失。在计算 IoU 时，会将预测框与真实框之间的区域纳入考虑范围。此外，该方法还采用梯度增益技术，既确保了高质量的锚框效果，又能减少有害梯度的影响，从而提升整体算法的性能。

$$L_{WIoUv3}=rL_{WIoUv1} \tag{6}$$

$$L_{WIoUv1}=R_{WIoU}L_{IoU} \tag{7}$$

$$R_{WIoU}=\exp\left(\frac{(x-x_{gt})^2+(y-y_{gt})^2}{(W_g^2+H_g^2)^*}\right) \tag{8}$$

$$r=\frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{9}$$

$$\beta=\frac{L_{IoU}^*}{\overline{L}_{IoU}} \tag{10}$$

式中，r 为非单调聚焦参数；x，y 为预测框的中心坐标；x_{gt}，y_{gt} 为真实框的中心坐标；W_g 和 H_g 为真实框的宽和高；* 表示将 W_g 和 H_g 从计算中分离；IoU 为预测框和真实框的交并比；β 为离群度；α，δ 为超参数；$\overline{L}_{IoU}$ 为 L_{IoU} 的动态值。具体表示情况如图 8 所示。

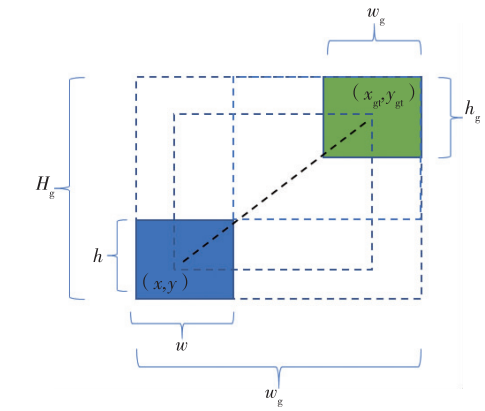


图 8 损失函数参数示意图

3 实验结果与分析

3.1 实验环境

在 Windows10 操作系统下进行实验验证，处理器型号为 12th Gen Intel(R) Core(TM) i5-12400 2.50 GHz，显卡型号为 NVIDIA RTX3060Ti，编程语言为 Python3.10.9，深度学习框架为 Pytorch2.3.0。

3.2 实验数据集

KITTI 数据集是目前国际上最为常用的自动驾驶场景下的计算机视觉算法评测数据集之一。数据集包含在市区、乡村和高速公路等场景下采集的真实图像数据，每张图像中最多达 15 辆车，还有各种程度的遮挡与截断。数据集存在各种尺度的车辆目标，且小尺寸车辆所占比例较高，符合实际交通场景，适合本文的模型训练。

数据集 KITTI 中共有 7 481 张真实交通场景图像，实验将其分成两部分：6 028 张图像用于训练数据集，1 453 张图像用于测试数据集。

3.3 评价指标

为了方便评价模型改进后的性能，将准确率(P)、召回率(R)、平均精度(mAP)、Giga 浮点运算每秒(GFLOPs)、权重文件大小作为评价指标：

P 为所有预测为正样本的结果中，预测正确的比率。定义式如下：

$$P=\frac{TP}{TP+FP} \tag{11}$$

R 是指在所有实际正例中，模型正确识别为正例的比例。定义式为：

$$R=\frac{TP}{TP+FN} \tag{12}$$

式中，TP 表示检测结果中预测正确的样本数量、FP 表示检测结果中预测错误的样本数量、FN 表示样本所有正确目标中未被检测到的数量。

mAP 基于目标检测中 m 个类别各自的精度-召回曲线来计算，较全面地反映网络的性能。定义式为：

$$mAP=\frac{1}{m}\sum_{i=1}^{m}\int_0^1 P(R)\mathrm{d}R \tag{13}$$

GFLOPs 与权重文件的大小是度量模型复杂度的指标。GFLOPs 与权重文件越小，表示模型所需要的算力就越小。

3.4 对比实验

为验证本算法的先进性，使用 KITTI 数据集，在目前主流的目标检测网络中分别进行训练及测试，形成对比实验，相关实验结果见表 1。

表 1 不同网络实验对比

网络模型	mAP@0.5(%)	模型大小/MB	参数量/百万	$GFLOPs$
Resnet50-SSD	0.571	104	24.1	61.2
MobileNetv2-Faster R-CNN	0.683	628	136.8	369.8
YOLOv5s	0.823	14.3	7.023	15.8
YOLOv7	0.939	74.8	37.2	105.2
YOLOv8s	0.927	22.5	11.127	28.4
本文	0.942	19.2	9.465	25.3

分析表 1 可知，SSD 以及 Faster R-CNN 这些经典网络模型的精度不高；YOLOv5s 参数数量少，然而检测精度较低；YOLOv7 和 YOLOv8s 精度提升，但参数量、计算量大。本文算法在检测精度以及参数量和运算量等方面都达到了平衡。

3.5 消融实验

为验证各项改进的有效性，以 YOLOv8s 模型为 Baseline 进行不同改进来做对比实验，训练数据集为 KITTI，表 2 给出了相关实验结果。

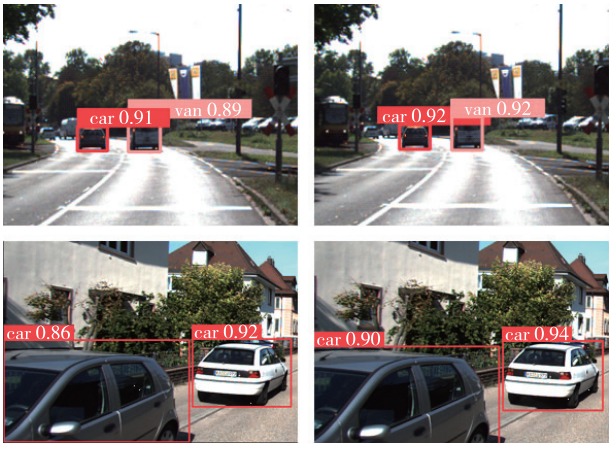
表 2 消融实验对比

改进	P/%	R/%	mAP@0.5(%)	模型大小/MB	参数量/百万	$GFLOPs$
Baseline	0.922	0.865	0.927	22.5	11.127	28.4
Baseline+FADC	0.93	0.859	0.927	22.6	11.162	28.0
Baseline+FADC+LSH	0.948	0.865	0.936	19.2	9.465	25.3
Baseline+FADC+LSH+WIoU	0.951	0.881	0.942	19.2	9.465	25.3

原始 YOLOv8s 的精确率为 92.2%，召回率为 86.75%，IoU 标准取 0.5 的 mAP 为 92.7%，模型

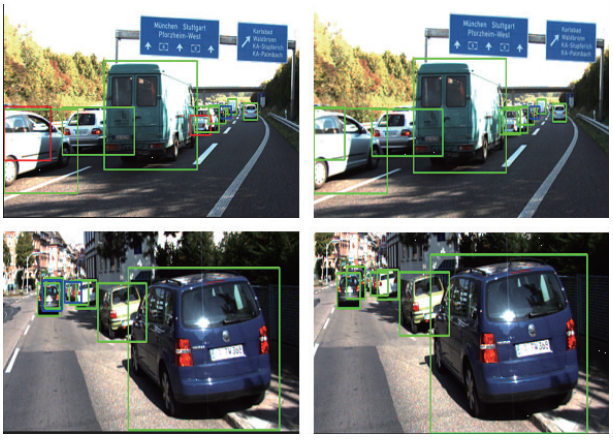
大小为 22.5 MB。只添加 FADC 模块时，对车辆特征的提取能力有提升，所以精确率 P 有所提升，在此基础上改进检测头后模型的参数量和模型大小都有效减小，最后引入的 WIoU 损失函数进一步改善了模型性能。可以看到，最终的模型比 Baseline 的平均检测精度提升 2.9%，网络参数量减少 14.9%，模型大小减少 14.6%。

图 9 显示了本文模型与 YOLOv8s 模型的部分预测结果对比，结果表明，在相同检测场景下，本文模型有更高的识别精度。图 10 为预测结果的可视化，其中绿色、蓝色和红色的方框分别表示真阳性（TP）、假阳性（FP）和假阴性（FN）预测。对比可以看出 LCD-YOLO 在小目标以及有遮挡的情况下检测效果有所改进。



（a）YOLOv8s　　（b）LCD-YOLOv8s

图 9　预测结果对比



（a）YOLOv8s　　（b）LCD-YOLOv8s

图 10　预测结果可视化

4　结论

本文提出了一种改进的 LCD-YOLO 算法，该算法首先使用 FADC 优化 YOLOv8s 中 C2f 的 Bottleneck，加强特征提取；提出一种轻量化共享卷积检测头，减少网络参数量并保持识别精度；同时，在尽量不增加模型复杂度的情况下，采用 WIoU 作为损失函数，提高边框检测精度。与传统 YOLOv8s 模型相比，所提出算法在计算量和参数量显著下降的同时保证了精度，能对行车进行有效识别，更好满足车辆实际检测的需求，对行车安全和辅助驾驶有重要意义。

参考文献：

[1] Sivaraman S, Trivedi M M. Looking at vehicles on the road: A survey of vision-based vehicle detection, tracking, and behavior analysis [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(4): 1773-1795.

[2] Han F, Shan Y, Cekander R, et al. A two-stage approach to people and vehicle detection with HOG-based SVM [C]// Performance Metrics for Intelligent Systems Workshop, 2006: 133-140.

[3] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Conf. on Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.

[4] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Trans. on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.

[5] Girshick R. Fast R-CNN [C]// International Conf. on Computer Vision (ICCV), 2015: 1440-1448.

[6] Redmon J, Divvala S, Girshick R, et al. You Only Look Once: Unified, real-time object detection [C]// Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.

[7] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Conf. on Computer Vision and Pattern Recognition (CVPR), 2023: 7464-7475.

[8] Li C, Li L, Jiang H, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. arXiv preprint arXiv: 2209.02976, 2022.

[9] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. arXiv preprint arXiv: 2004.10934, 2020.

[10] Redmon J, Farhadi A. YOLOv3: An incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.

[11] Redmon J, Farhadi A. YOLO9000: Better, faster, stronger [C]// IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2017: 6517-6525.

[12] 陈争志，刘国巍. 基于改进 YOLOv8 的车辆检测算法研究[J/OL]. 重庆工商大学学报(自然科学版), 1-9[2024-12-24].
Chen Zhengzhi, Liu Guowei. Research on vehicle detection

algorithm based on improved YOLOv8 [J/OL]. Journal of Chongqing Technology and Business University (Natural Science Edition), 1-9[2024-12-24].

[13] Wei L, Dragomir A, Dumitru E, et al. SSD: Single shot multibox detector[C]// Computer Vision-ECCV, 2016: 21-37.

[14] 郭宇阳, 胡伟超, 戴 帅, 等. 面向路侧交通监控场景的轻量车辆检测模型[J]. 计算机工程与应用, 2022, 58(6): 192-199.

Guo Yuyang, Hu Weichao, Dai Shuai, et al. Lightweight vehicle detection model for roadside traffic monitoring scenarios [J]. Computer Engineering and Applications, 2022, 58(6): 192-199.

[15] Li Z, Pang C, Dong C, et al. R-YOLOv5: A lightweight rotational object detection algorithm for real-time detection of vehicles in dense scenes[J]. IEEE Access, 2023, 11: 61546-61559.

[16] Wu Y, Tang Y, Yang T. An improved nighttime people and vehicle detection algorithm based on YOLOv7 [C]// 3rd International Conference on Neural Networks, Information and Communication Engineering (NNICE), 2023: 266-270.

[17] Chen L, Gu L, Zheng D, et al. Frequency-adaptive dilated convolution for semantic segmentation [C]// Conf. on Computer Vision and Pattern Recognition (CVPR), 2024: 3414-3425.

[18] Tian Z, Shen C, Chen H, et al. FCOS: A simple and strong anchor-free object detector[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 1922-1933.

作者简介:

代少升(1974—),男,河南省潢川县人,博士,教授,主要从事红外成像系统及 SOPC 嵌入式系统设计与开发;

余自安(1974—),男,河南省光山县人,高级工程师,主要从事机械设计及理论研究。