

DOI:10.19651/j.cnki.emt.2212220

基于改进 YOLOv5s 的无人驾驶夜间车辆 目标检测算法*

张 蕊 高诗博 赵 霞 侯先磊

(北京建筑大学土木与交通工程学院 北京 100044)

摘 要: 夜间车辆检测对无人驾驶车辆行驶安全具有重要意义。但是,夜间光照强度低,车辆几何特征呈现不明显,尤其远处车辆由于目标小而特征视认难,导致检测难度大幅提升。基于此,提出了一种基于改进 YOLOv5s 的无人驾驶夜间车辆检测算法。首先,采集榆林市部分道路夜间场景自构建数据集,并通过 Retinex 算法实现数据增强处理;在此基础上,进一步通过以下 3 个措施对传统 YOLOv5s 网络进行改进:将深度可分离卷积引入 Backbone 结构,减少网络参数量;将多种注意力机制与 FPN 融合,提升网络的特征提取能力;在 PAN 中引入空洞卷积,在感受野不变和特征信息损失较少的同时,减少网络参数量。最终实验结果显示:夜间车辆的平均检测精度可达 84.8%,相较改进前提升了 5.2%;对应检测速度可达 48 fps,提升了 9.1%。研究成果可为提升无人驾驶车辆在事故多发夜间时段的行车安全性奠定理论基础。

关键词: 深度学习;夜间车辆检测;YOLOv5;注意力机制;深度可分离卷积;空洞卷积

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.2099

Algorithm on nighttime target detection for unmanned vehicles based on an improved YOLOv5s

Zhang Rui Gao Shibo Zhao Xia Hou Xianlei

(School of Civil and Transportation Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract: Nighttime vehicle detection is of great significance to the safety of unmanned vehicles. At night, low light intensity makes the geometric characteristics of a vehicle inconspicuous. Moreover, a remote vehicle is even difficult to be recognized due to its small size, thus resulting in a significant increase of difficulty in its detection. In this context, this paper proposes an algorithm on nighttime target detection for unmanned vehicles based on an improved YOLOv5s model. To begin with, some night scenes concerning roads in Yulin City are collected for dataset construction. The data is then enhanced by Retinex algorithm. On this basis, the following three measures are made to improve the traditional YOLOv5s network: introducing depthwise separable convolution into the Backbone structure to reduce the number of network parameters; combining multiple attention mechanisms with the FPN structure to improve the ability of feature extraction of the network; embedding dilated convolution into the PAN structure to reduce the number of network parameters, as well as the loss of feature information, while keeping the receptive field unchanged at the same time. The final experimental results demonstrate that the average accuracy of nighttime vehicle detection reaches 84.8%, which is 5.2% higher than before. The corresponding detection speed is up to 48 frames per second, an increase of 9.1%. The research results can lay a theoretical foundation for improving the driving safety of unmanned vehicles during accident-prone nights.

Keywords: deep learning; nighttime target detection; YOLOv5; attention mechanism; depthwise separable convolution; dilated convolution

0 引 言

无人驾驶车辆在事故多发的夜间时段行车存在巨大的

安全隐患。究其原因,无人驾驶车辆在夜间行驶过程中,由于光照强度较低,可视距离下降,前方远处车辆目标较小,导致检测难度加大。提升车辆检测的精度和速度是保障无

收稿日期:2022-11-28

* 基金项目:国家自然科学基金青年基金(5170080357)、北京未来城市设计高精尖创新中心项目(UDC2019032924)、住房和城乡建设部软科学研究项目(2018-R2-046)资助

人驾驶车辆夜间安全行驶的重要手段,关键在于提出一种适用于无人驾驶车辆的夜间车辆检测算法。

当前目标检测的经典算法是 YOLO(you only look once) 系列算法^[1-3]。YOLO 主要的网络结构包括:负责特征提取的 Backbone 层、负责特征融合的 Neck 层以及负责分类结果预测并输出的 Head 层。其中,Neck 层又可细分为自底向上的网络结构 FPN(feature pyramid network)和自顶向下的网络结构 PAN(path aggregation network)。以 YOLO 算法为代表的目标检测算法对大目标车辆检测^[4]发展较为成熟,而对夜间小目标车辆的检测仍是重点和难点,且相关研究较少,关键在于提出一种精度高、速度快的网络来检测夜间小目标车辆。李慧等^[5]通过提取和匹配夜间车辆的前后车灯特征来实现了 87.22% 的车辆检测率。但该做法依赖特征的提取,且仅通过车灯特征进行检测,会导致该方法对小目标车辆的检测精度较低。张炳力等^[6]基于 RetinaNet 通过改进分类损失和定位损失,提高了夜间小目标车辆的检测能力,但引入了新的参数量会导致检测速度下降。

通过进一步综述现有的小目标检测算法,可发现:引入注意力机制^[7]来模拟人眼观察目标是目前常用的提升检测网络对小目标关注度的方式,从而提升对它的特征提取能力^[8-11]。例如,吴双忱等^[12]在目标检测网络中引入通道注意力机制 SEnet(squeeze and excitation net),来提升网络对小目标的特征提取能力。但由于输出特征多数来自某一个通道,导致其他通道的特征信息不够充分。赵凤等^[13]基于 YOLOv4-tiny 模型,将带有空间位置信息的注意力机制引入特征金字塔,来提升网络的检测精度。考虑到特征金字塔结构中的特征图通道数通常较多,若对所有的通道都赋予相同的关注度,会导致计算资源浪费,网络响应速度降低。在这种情况下,王怡雯等^[14]基于 YOLOv4 模型,在自顶向下的网络结构 PAN 结构中引入由通道注意力机制和串行空间注意力机制的 CBAM 模块(convolutional block attention module),来获得不同尺度目标的特征信息,进而增强对小目标车辆的特征提取能力。但 CBAM 模块会在网络中引入较多参数,导致网络响应速度较慢。赵璐璐等^[15]基于 YOLOv5s 模型,在网络不同位置引入注意力机制,发现引入 Neck 层有利于提升模型的检测精度。为解决由引入额外参数引起的网络响应速度较慢的问题,黄凯文等^[16]在 YOLOv4-tiny 的 CSP 结构中加入深度可分离卷积,使网络参数量减少了 52%,极大提升了网络的响应速度。王银等^[17]同样基于 YOLOv4 模型,在 PAN 结构中引入深度可分离卷积,同样也将参数量减少了 42%,提升了网络响应速度。类似地,李昭慧等^[18]基于 YOLOv4 模型,在 PAN 结构中加入了空洞卷积,仅依赖少量参数,即可扩大感受野,并提升网络的检测精度。徐镭等^[19]基于 YOLOv3 网络结构,在 3 个特征图中引入 3 种扩张率

的车辆数据集较少,导致特征信息缺乏;2)在网络中引入单一的注意力机制仍缺乏一定的特征提取能力;3)引入注意力机制会带来大量的参数量,导致网络响应速度较慢。

针对上述问题,本文提出了一种基于改进 YOLOv5s 模型的夜间车辆检测算法,来提高无人驾驶车辆对前方车辆的检测精度及速度。具体而言,本文首先自制了夜间车辆数据集,并运用 Retinex 算法对数据集进行图像增强,消除车灯自身对于车辆几何特征的遮挡影响;其次,对传统的 YOLOv5s 模型进行如下 3 项改进,来提升网络对小目标的检测能力,包括:1)在 Backbone 结构中引入深度可分离卷积,来减少伴随注意力模块的网络参数量;2)在 FPN 结构中引入多种注意力机制,来提升网络对夜间车辆的特征提取能力;3)在 PAN 结构中使用空洞卷积代替传统卷积,在感受野不变的前提下,实现网络参数量的削减。实验结果显示,本文提出的改进算法在检测精度和速度上都较改进前有较大提升。

1 网络结构改进

本文在改进经典的 YOLOv5s 网络结构的基础上,提出了一种新的网络结构模型,即:多种注意力机制-YOLOv5s-深度可分离-空洞卷积(multi attention-YOLOv5s-depthwise separable-dilated convolution, MA-YOLOv5s-DS-DC),以适用于小目标物体检测。所提模型的网络结构如图 1 所示。针对 Backbone 层,将 CBL 结构之中的传统卷积替换为深度可分离卷积;针对 Neck 层的 FPN 结构,引入 SEnet、CBAM、SA (spatial attention)模块来增强网络的特征提取能力;针对 Neck 层的 PAN 结构,引入空洞卷积,保证感受野不变的同时,减少卷积过程中的参数量。

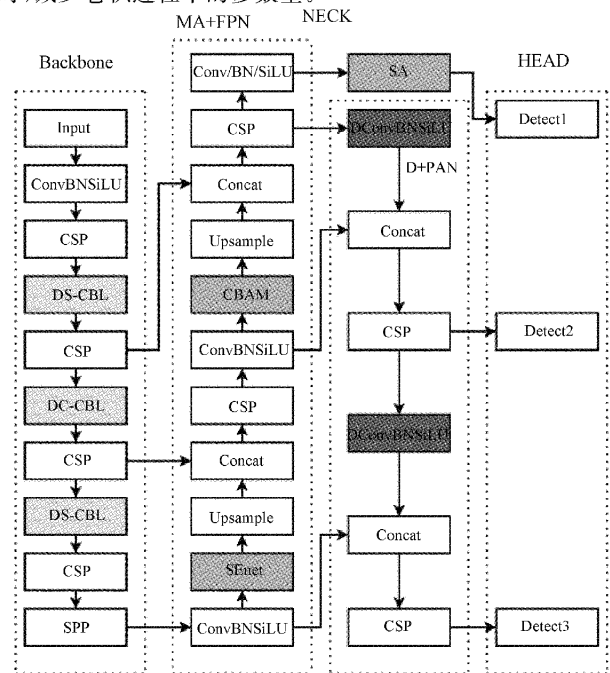


图 1 MA-YOLOv5s-DS-DC 结构

1.1 基于深度可分离卷积的 Backbone 结构改进

深度可分离卷积 (depthwise separable convolution, DSconv) 的核心思想在于让每个特征图通道对应一个卷积块,从而降低卷积过程中的参数量,提升网络响应速度^[20]。如图 2 所示,它主要由深度卷积和逐点卷积构成。




图 2 深度可分离卷积结构

传统卷积层和深度可分离卷积的参数量为:

$$P = h \times h \times c \times f \quad (1)$$

$$P_d = (h \times h \times c) + (c \times f \times 1 \times 1) \quad (2)$$

式中: P 为传统卷积参数量, P_d 为深度可分离卷积参数量, h 为卷积核尺寸, c 为卷积核个数, f 为输出特征图通道数。

由于 YOLOv5s 的 Backbone 层中的 CSP 结构具有强化特征提取的作用,在此结构中加入深度可分离卷积会导致网络特征提取能力下降。因此,本文在保留 CSP 结构中的传统卷积的基础上,将 CBL 结构中的传统卷积替换为深度可分离卷积,在保证网络特征提取能力的同时,减少其中的参数,提升网络的响应速度。图 3 展示了改进后的 CBL 结构,即:DS-CBL(depthwise separable-CBL)。

1.2 基于多种注意力机制的 MA+FPN 结构改进

现有研究^[21]指出,FPN 结构会产生 3 种不同尺寸和通道维度的特征图。在第 1 次上采样前,这 2 种参数的量级达到最大;第 2 次二者的量级依然较大;第 3 次特征图尺寸最大而通道数最少。若只添加单一的注意力机制,车辆特征将较难在空间和通道维度中平衡。因此,论文在第一次上采样 FPN 结构前,引入了考虑了通道信息的网络结构 SEnet,加强网络对特征图重要通道的关注度,抑制噪声通道;在第二次上采样前,添加一个由通道注意力机制和空间注意力机制串行的 CBAM 模块,从而在通道及空间维度共同提升网络对小目标车辆特征的关注度;在此之后,考虑到

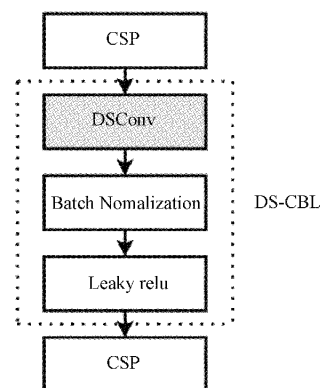


图 3 改进后的 DS-CBL 结构

数据集中小目标车辆样本较多,且其尺寸在较小特征图中的空间占比较低,故引入考虑空间信息的注意力模块 SA,来提升网络对小目标车辆的特征提取能力。改进后的 MA+FPN(multiple attention+FPN)结构如图 4。

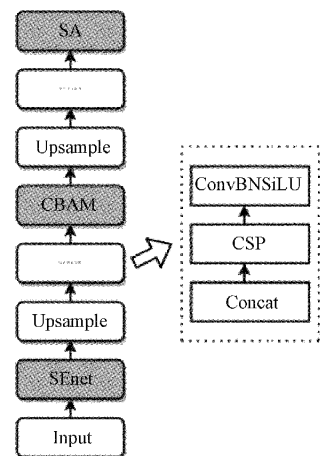


图 4 自底向上的 MA+FPN 结构

空间注意力 SA 的网络结构如图 5 所示。如图可知,SA 将输入的车辆特征图池化后进行一次卷积,然后再通过激活函数获得特征图中各个像素点的权重,最后将它与原特征图做乘积得到输出特征图,从而增强网络在空间维度上的特征提取能力。

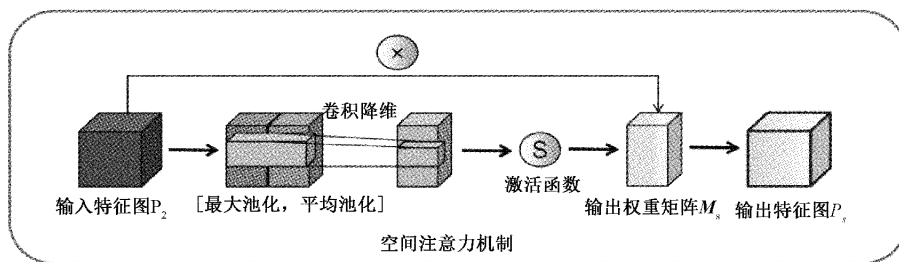


图 5 空间注意力机制结构

通道注意力机制 SEnet^[22]的网络结构如图 6 所示。如图可知,SEnet 将输入特征图通道压缩为 $1 \times 1 \times C$ 的向量

(C 为通道数),并通过 2 个共享的全连接层和激活函数来获得每个通道的权重系数,从而提升网络在通道维度上

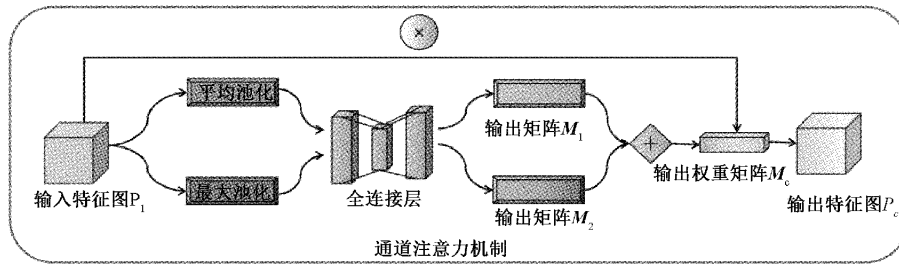


图 6 通道注意力机制结构

的特征提取能力。

混合注意力机制 CBAM^[23] 的网络结构如图 7 所示。如图可知, CBAM 从通道和空间两方面对特征图进行权重

计算, 并分别为二者增加注意力机制, 使网络在上述两种维度上提升其特征提取的能力。

为了增加注意力机制的可解释性, 本文通过 Grad-CAM




图 7 CBAM 注意力机制结构

(gradient-weighted class activation Mapping) 算法^[24] 对图像进行热成像可视化处理。如图 8(a) 所示, 若只引入单一的注意力机制 SEnet, 网络的关注度范围较大, 导致它将耗费更多的计算资源在主体特征之外。相比之下, 若引入多种注意力机制, 网络将集中关注车辆的主体位置, 使网络能够更多关注小目标车辆的特征, 如图 8(b)。




图 8 改进前后的注意力机制可视化

1.3 基于空洞卷积的 D+PAN 结构改进

空洞卷积(dilated convolution, DConv)^[25] 的核心工作原理是: 在卷积核中加入一个超参数值, 即空洞扩张率, 来扩大卷积核, 使其在卷积感受野不变的情况下, 减少参数量。图 9(a) 和 (b) 的对比结果正好印证这一结论。即: 为了在特征图上选取感受野为 3 的区域, 大小为 3 的卷积核需要使用 9 个参数, 而空洞卷积仅需 4 个。此外, 通过对比图 9(a) 和 (c) 可知: 当卷积核与空洞卷积同样使用 9 个参数时, 后者在特征图上将拥有更大的感受野。

原始网络 PAN 结构中采用步长为 2 的卷积核对特征图进行卷积, 以实现下采样操作的效果, 从而与 FPN 结构中得到的 3 种不同尺度的特征图进行特征融合。但若使




图 9 传统卷积与空洞卷积感受野

用传统的卷积核会导致网络在此产生大量的参数, 降低网络的响应速度, 且过大的步长也会导卷积过程中特征信息的损失, 从而降低无人驾驶车辆对前方车辆的检测速度和检测精度。因此, 本文将原始 PAN 结构中的传统卷积替换为空洞卷积。改进后的 D+PAN(Dilated+PAN) 结构如图 10 所示。

2 实验方法与结果分析

本文网络训练所使用的计算机系统为 Windows 11, 计算机处理器为 11th Gen Intel(R) Core(TM) i7-11800H@2.30 GHz 2.30 GHz, 显卡为 NVIDIA GeForce RTX 3070, 运行内存 32 GB。

实验设置训练轮次为 150 个 Epoch; batch size 为 16; 输入图像尺寸为 640×640; 学习率迭代算法为余弦退火; 使用 Adam 作为优化算法; 初始学习率为 0.001。

2.1 实验数据集

考虑车辆夜间实际行驶环境和安全车距, 本文拍摄夜间环境(0.003~10 lux)下 10~100 m 内的车辆照片共计




图 10 改进后自顶向下的 D+PAN 结构

1 000 张,来作为本文数据集。此外,使用精灵标注软件对拍摄的夜间车辆照片集进行信息标注,并按 8 : 1 : 1 的比例将原始数据集切割为训练集、验证集及测试集。

考虑到夜间车辆车头和车尾的灯光会削弱车辆几何特征,致使车辆特征提取困难,如图 11(a),因此,本文采用 Retinex^[26]算法,对自制数据集进行了图像增强操作,来削减车辆自身灯光对检测效果的干扰。Retinex 算法的工作原理是:从原始图像中估计光照,分解出反射率,消除光照不均的影响,从而消除车辆灯光对车辆几何特征的影响。通过对比图 11(a)、(b):增强后的车辆几何特征变得更加清晰,如图 11(b)。




图 11 图像增强前后效果对比

2.2 实验指标

本文选取平均精度 (average precision, AP) 作为网络检测精度的评价指标。

$$AP = \sum_{i=1}^n \int f\left(\frac{TP}{TP+FP}, \frac{TP}{TP+TN}\right) \quad (3)$$

式中: TP (true positive) 代表将真实车辆检测为正样本的数量; FP (false positives) 代表将非车辆检测为正样本的数量; TN (true negatives) 代表将真实车辆检测为负样本的数量; FN (false negatives) 代表将非车辆检测为负样本的数量。

考虑到本文目标检测网络部署设备为无人驾驶车辆,因此进一步引入 FPS(frames per second)作为检测速度的评价指标。FPS 指每秒能够检测图像的数量。

2.3 实验结果及分析

论文对网络进行了 150 个 Epoch 的训练。网络的分类损失在第 20 个 Epoch 时就表现出了较好的收敛性,如图 12(a);同时,网络精确度在第 30 个 Epoch 时达到了较高的水平,最高达到 0.94,可说明本文改进效果理想,如图 12(b)所示。




图 12 本文网络性能

使用 YOLOv5s 和本文网络分别在 VOC2007 公开数据集以及本文数据集上进行实验,由于公开数据集解决的是一类通用问题,因此数据集中白天样本和夜间样本,以及大目标和小目标存在不平衡性,而本文自制数据集中标注了更多的夜间小目标车辆的特征。结果显示:相比 VOC2007 数据集,YOLOv5s 在本文数据集上的 AP 提升了 3.9%,本文网络 AP 提升了 4.7%,如表 1 所示。

表 1 数据集 AP 对比结果 %

网络类型	VOC2007	本文数据集
YOLOv5s	75.7	79.6
本文网络	80.1	84.8

为了对比不同的空洞卷积扩张率对网络训练结果的影响,通过调整不同的空洞扩张率,对网络进行训练,结果如图 13 所示。

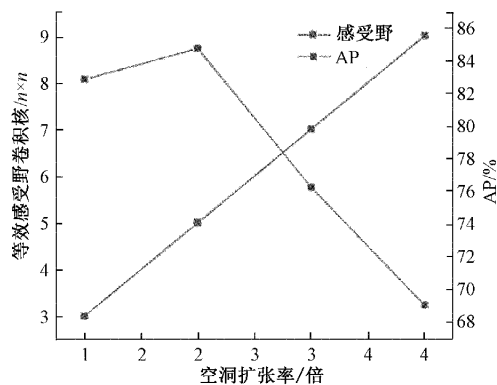


图 13 不同空洞扩张率下的感受野和 AP

由于过大的空洞扩张率会导致小目标车辆落入空洞之中,产生较多的小目标车辆漏检。当空洞扩张率为 2

时,网络训练后的 AP 值为 84.8%,为实验中最大值,因此选择空洞扩张率为 2 作为空洞卷积的扩张率。

为了验证本文目标检测网络的性能优越性,将本文网络与原始 YOLOv5s 网络以及当前较为主流的目标检测网络在本文数据集上进行对比实验,结果如表 2 所示。

表 2 各目标检测网络的性能对比

网络类型	AP/%	参数量	FPS
YOLOv5s	79.6	7.23×10^6	44
SSD	75.4	2.34×10^7	37
RetinaNet	78.8	1.64×10^7	39
本文网络	84.8	5.42×10^6	48

本文改进的 YOLOv5s 相较于 SSD 及 RetinaNet 主流的目标检测网络,在检测精度和检测速度上均有明显提升;相较改进前网络,本文的 AP 提升了 5.2%,FPS 提升了 4。

同时,本文设计了消融实验来验证本文改进网络的有效性,MA(multiple attention)代表多种注意力机制,“√”代表使用了该方法,“×”代表未使用该方法,如表 3 所示。

表 3 本文网络消融实验结果

基础网络	深度可 分离卷积	空洞 卷积	MA	AP/ %	FPS/ 帧
YOLOV5s	×	×	×	79.6	44
	√	×	×	78.9	47
	√	√	×	78.1	49
	√	√	√	84.8	48

由表可知,原始 YOLOv5s 网络在本文数据集上的 AP 为 79.6%,FPS 值为 44,即每秒钟可检测图像为 44 帧,在 Backbone 中引入深度可分离卷积后,由于替换了逐通道卷积的方式,特征提取能力略微下降,导致 AP 值略微下降,而 FPS 增长显著,由 44 提升到了 47,其原因为深度可分离卷积降低了整个网络中的计算参数,提升了网络的响应速度。在引入空洞卷积后,在没有改变原卷积感受野的前提下,减少了卷积参数量,进而提升了网络的响应速度,FPS 提高了 2%,而由于空洞卷积会使得图像中个别小车辆目标落入空洞之中,导致了网络产生对个别细小车辆目标的漏检,因此值产生了略微的下降,在此基础上,增加多种注意力机制后,网络的 AP 提升了 6.7%,是因为在多种注意力机制的作用下,抑制了空间及通道中噪声信息,在通道和空间维度上增加了网络对夜间车辆主体特征的关注度,增加了网络对图像中车辆主体目标的特征提取能力,使得网络的 AP 提升到了 84.8%,且 FPS 值达到了 48,相较 YOLOv5s 原始网络,AP 值提升了 5.2%。检测速度提升 9.1%。

最后将本文网络与 YOLOv5s 原始网络在本文自制数据下做检测可视化检测,如图 14 所示(左为改进前效果,右为改进后效果),可以看到原始的 YOLOv5s 网络在对夜间一些远距离的小目标车辆检测时会出现漏检的现象,而本文网络在对夜间远距离小目标车辆检测时出现的漏检个数小于原始的 YOLOv5s 网络。同时本文网络对车辆灯光较强车辆的检测鲁棒性较强,不易由于车辆灯光较强导致的几何特征不明显而产生漏检错检测的问题,总而言之,本文基于 YOLOv5s 改进的网络在对夜间车辆尤其是远处小目标车辆的检测性能上,相较于原始网络,漏检率更低,且检测速度更快,具有更好的效果。




图 14 改进前后检测结果对比图

3 结 论

本文提出了一种适用于无人驾驶任务的基于改进YOLOv5s模型的夜间车辆检测算法。首先,从实际场景中自构建了夜间车辆数据集,并基于Retinex算法消除车灯对车辆特征的影响因素,增强车辆特征。在目标检测网络层面,在Backbone中引入深度可分离卷积,减少了网络参数量;并设计了一种改进的FPN结构,通过引入CBAM和SENet及SA提升了网络对于夜间车辆特征的提取能力,AP值提升了5.2%;为平衡引入注意力机制模块而增加的参数量,在网络PAN中使用空洞卷积代替传统卷积,在感受野不变的同时,减少了网络的参数量,提升了网络的检测速度,FPS值最终提升9.1%。相较于原始网络检测精度和检测速度均有提升,研究成果可为提升无人驾驶车辆在事故多发夜间时段的行车安全性奠定理论基础。

需要指出的是:本文是有监督学习(supervised learning,SL),网络性能依赖于给定的数据集标签。而无监督学习可以根据样本间的相关性规律,构建新的数据模型,从而节省大量数据标记的时间。因此在未来研究中,可以进一步借鉴无监督学习思想,优化研究结果。

参考文献

- [1] 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, Las Vegas, USA, 2016: 779-788.
- [2] REDMON J and FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv Preprint, 2018, ArXiv: 1804.02767.
- [3] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [4] 刘超阳, 曲金帅, 范菁, 等. 基于改进YOLOv5算法的车辆目标检测[J]. 云南民族大学学报(自然科学版), 2022, 31(6): 749-754.
- [5] 李慧, 白鹏飞, 李世晓, 等. 基于车灯特征的夜间车辆检测方法[J]. 电子测量技术, 2020, 43(14): 89-95.
- [6] 张炳力, 秦浩然, 江尚, 等. 基于RetinaNet及优化损失函数的夜间车辆检测方法[J]. 汽车工程, 2021, 43(8): 1195-1202.
- [7] 李经宇, 杨静, 孔斌, 等. 基于注意力机制的多尺度车辆行人检测算法[J]. 光学精密工程, 2021, 29(6): 1448-1458.
- [8] 李永上, 马荣贵, 张美月. 改进YOLOv5s+DeepSORT的监控视频车流量统计[J]. 计算机工程与应用, 2022, 58(5): 271-279.
- [9] 李宇琼, 周永军, 蒋淑霞, 等. 基于注意力机制的交通标志识别[J]. 电子测量技术, 2022, 45(8): 116-120.
- [10] 张上, 王恒涛, 冉秀康. 基于YOLOv5的轻量化交通标志检测方法[J]. 电子测量技术, 2022, 45(8): 129-135.
- [11] 郑美琳, 高建瓴. 融合多注意力机制与PointRCNN的三维点云目标检测[J]. 电子测量技术, 2022, 45(9): 127-132.
- [12] 吴双忱, 左峥嵘. 基于深度卷积神经网络的红外小目标检测[J]. 红外与毫米波学报, 2019, 38(3): 371-380.
- [13] 赵凤, 李永恒, 李晶, 等. 基于改进YOLOv4-tiny的轻量化室内人员目标检测算法[J]. 电子与信息学报, 2022, 44(11): 3815-3824.
- [14] 王怡雯, 王学军, 穆应晨. 基于改进YOLOv4的道路红外场景下的行人车辆目标检测研究[J]. 科学技术创新, 2021(28): 72-74.
- [15] 赵璐璐, 王学营, 张翼, 等. 基于YOLOv5s融合SENet的车辆目标检测技术研究[J]. 图学学报, 2022, 43(5): 776-782.
- [16] 黄凯文, 凌六一, 王成军, 等. 基于改进YOLO和DeepSORT的实时多目标跟踪算法[J]. 电子测量技术, 2022, 45(6): 7-13.
- [17] 王银, 王飞翔, 孙前来. 多尺度特征融合车辆检测方法[J]. 系统仿真学报, 2022, 34(6): 1219-1229.
- [18] 李昭慧, 张玮良. 基于改进YOLOv4算法的疲劳驾驶检测[J]. 电子测量技术, 2021, 44(13): 73-78.
- [19] 徐疆, 朱洪锦, 范洪辉, 等. 改进的YOLOv3网络在钢板表面缺陷检测研究[J]. 计算机工程与应用, 2020, 56(16): 265-272.
- [20] 张曼, 叶曦, 李杰, 等. 基于深度可分离卷积的卫星影像检测技术研究[J]. 计算机仿真, 2022, 39(2): 17-22, 97.
- [21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature Pyramid Networks for Object Detection[J]. ArXiv Preprint, 2016, ArXiv: 1612.03144.
- [22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany. ECCV, 2018: 3-19.
- [24] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.
- [25] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. ArXiv Preprint, 2015, ArXiv: 1511.07122.
- [26] 欧嘉敏, 胡晓, 杨佳信. 改进Retinex-Net的低光照图像增强算法[J]. 模式识别与人工智能, 2021, 34(1): 77-86.

作者简介

高诗博, 硕士, 主要研究方向为交通运输规划与管理、智能交通等。

E-mail: m13347480098@163.com