

DOI:10.20035/j.issn.1671-2668.2024.05.002

引用格式:霍婷婷,晏永,方永锋,等.基于 YOLOv5 的夜间交通道路车辆检测方法设计[J].公路与汽运,2024,40(5):9-19.

Citation:HUO Tingting, YAN Yong, FANG Yongfeng, et al. Design of vehicle detection method for night traffic based on YOLOv5[J]. Highways & Automotive Applications, 2024, 40(5): 9-19.

基于 YOLOv5 的夜间交通道路车辆检测方法设计*

霍婷婷¹, 晏永², 方永锋¹, 李艳¹, 张庆¹, 苗海东¹

(1.宁夏师范学院 物理与电子信息工程学院, 宁夏 固原 756000; 2.中北大学 机电工程学院, 山西 太原 030051)

摘要: 针对夜晚环境中车流量统计的实时性、鲁棒性和准确性不高等问题,提出一种基于 YOLOv5 算法优化和摄像补光灯相配合的车辆检测方法,实现交通道路上车辆的精确检测,克服以往夜间图像模糊、光线昏暗等造成的检测不准确问题。采用基于 YOLOv5 深度学习的方法,以道路临时拍摄的图像构成数据集,以高斯函数构建数据增强图像进行车辆检测,其中检测系统的硬件采用芯片双回路设计控制补光装置,提高检测识别准确性,软件上对 YOLOv5 算法进行超参数优化,提升系统检测精确性和快速性;采集不同天气、不同补光强度下道路交通图像,通过优化后算法分析其有效性,结果表明,相较于原有检测方法,该方法的平均准确率(mean Average Precision, mAP)和检测帧速率(Frame Per Second, FPS)分别增加 4.2%、12%,检测效果较好。

关键词: 公路交通;车辆检测;夜间车辆统计;YOLOv5;数据增强;双回路设计;补光装置

中图分类号:U492.84

文献标志码:A

文章编号:1671-2668(2024)05-0009-11

如今道路交通拥堵问题日益突出,根据相关文献统计,公路交通事故在全球范围内造成的损失约 5 000 亿美元/年,以此推测,20 年后,公路交通事故将导致全球约 130 万人死亡^[1];中国 2018 年交强险赔付达 1 384 亿元;美国 2017 年交通拥堵造成的经济损失达 3 050 亿美元;北京 2017 年交通拥堵造成的时间成本损失达 1 049 元/月,占月均工资的 12.4%^[2]。为解决交通拥堵问题,很多专家就城市道路结构、城市规划、道路安全监控、公民交通安全意识等进行了研究,其中道路安全监控可为完善智能交通控制系统、解决交通拥堵问题提供数据支持。车辆检测作为道路安全监控的重要组成部分,已成为智能交通系统的研究热点之一^[3-5]。但由于夜间光照强度不足、环境灯干扰较大,夜间车辆检测困难。本文利用辅助补光装置进行补光,通过调整设备位置和补光强度,使夜间图像质量满足实际要求,提升夜间车辆识别准确性。同时对 YOLOv5 算法进行超参数优化和数据增强改进,提高检测速度和精度。

1 深度学习算法选择

与传统检测算法相比,深度学习能极大提高车

辆检测速度和准确率。目前最主流的深度学习算法有 R-CNN(Region-Convolutional Neural Networks)、Fast R-CNN、Faster R-CNN、YOLO(You Only Look Once)系列等^[6]。其中:R-CNN 利用卷积神经网络结构(CNN)对图像进行特征提取,检测图像较之前算法增加 53%;Fast R-CNN 的池化层采用 SPP(Spatial Pyramid Pooling)结构,候选框回归和目标分类在全连接层相结合,既能保证检测性能,还能将训练速度提升 9 倍^[7];Faster R-CNN 采用 RPN(Region Proposal Network)候选框生成算法,用网络训练的方式提取目标,替换之前的选择性搜索(Selective Search)算法,其检测速度和准确率均得到提升^[8];YOLO 系列算法虽然精度稍逊于 Fast R-CNN 算法,但其检测速度比 Fast R-CNN 算法快几十倍。

目标检测的深度学习模型中有两个非常重要的性能指标,一个是全类平均精度 mAP(mean Average Precision),另一个是检测帧速率 FPS(Frames Per Second)。mAP 主要通过精确率 P (Precision)、召回率 R (Recall)、准确率 A (Accuracy)计算得到^[9-10],计算公式如下:

* 基金项目:宁夏自然科学基金资助项目(2022AAC03319)

$$P = T_p / (T_p + F_p) \tag{1}$$

$$R = T_p / (T_p + F_N) \tag{2}$$

$$P_{AP} = \int_0^1 P(t) dt \tag{3}$$

$$P_{mAP} = (\sum_{n=1}^N P_{APn}) / N \tag{4}$$

式中： T_p 表示正样本被正确检测的数量； F_p 表示负

样本被检测成正样本的数量； F_N 表示正样本被检测成负样本的数量； P_{AP} 表示每个类别 P 的平均值； P_{mAP} 表示所有类别 P_{AP} 的平均值，即 Precision-Recall 曲线下面积的均值^[10-11]； N 表示类别个数。

将上述各深度学习算法的性能指标和原理进行比较(见表 1)，从中选择适合车辆检测的算法。

表 1 深度学习算法比较

算法	平均准确率 P_{mAP}	检测帧速率 R_{FPS}	算法原理
R-CNN	58.5	0.1	
Fast R-CNN	70.0	0.5	
Faster R-CNN	76.4	5.0	
YOLO	77.8	59.0	

由表 1 可知：YOLOv5 算法在检测精度上与 Faster R-CNN 相差不大，但其速度与 R-CNN 系列相比具有明显优势，且该算法更贴近工程应用。综合考虑，采用 YOLO 算法作为车辆检测识别技术方法。

2 YOLOv5 算法优化

2.1 算法概述

根据模型参数和浮点运算量的不同，将 YOLOv5 算法分为 s、m、l、x 4 个模型，4 个模型的参数和运算量依次增加。本文采用 YOLOv5 算法中参数和运算量最少的 s 模型作为基础模型。该模型具有 One-Stage 结构，整体由输入端(Input)、主干网络(Backbone)、网络层(Neck)、输出端(Head)

组成^[10]，其中输入端采集 640 px×640 px 的图片，经过数据增强和自适应锚框计算，通过主干网络和网络层提取特征值，最后输出对应的损失函数 IOU(Intersection Over Union Loss)值。其主要网络结构见表 2。

YOLOv5 有 29 个为各种训练设置的超参数，它们定义在/data 目录下的 yaml 文件中，通过参数设置可以改变模型学习率、损失权重及数据增强效果。在优化超参数前必须对其进行赋值，具体数值见表 3。

2.2 YOLOv5 超参数优化

YOLOv5 提供了一种超参数优化的方法(Hyperparameter Evolution)，其主要原理是遗传算

表 2 YOLOv5 算法架构

L/层	from	n/个	params	module	arguments
0	-1	1	3 520	models.common.Focus	[3,32,3]
1	-1	1	18 560	models.common.Conv	[32,64,3,2]
2	-1	1	18 816	models.common.C3	[64,64,1]
3	-1	1	73 984	models.common.Conv	[64,128,3,2]
4	-1	3	156 928	models.common.C3	[128,128,3]
5	-1	1	295 424	models.common.Conv	[128,256,3,2]
6	-1	3	625 152	models.common.C3	[256,256,3]
7	-1	1	1 180 672	models.common.Conv	[256,512,3,2]
8	-1	1	656 896	models.common.SPP	[512,512,[5,9,13]]
9	-1	1	1 182 720	models.common.C3	[512,512,1,False]
10	-1	1	131 584	models.common.Conv	[512,256,1,1]
11	-1	1	0	torch.nn.modules.upsampling.Upsample	[None,2,'nearest']
12	[-1,6]	1	0	models.common.Concat	[1]
13	-1	1	361 984	models.common.C3	[512,256,1,False]
14	-1	1	33 024	models.common.Conv	[256,128,1,1]
15	-1	1	0	torch.nn.modules.upsampling.Upsample	[None,2,'nearest']
16	[-1,4]	1	0	models.common.Concat	[1]
17	-1	1	90 880	models.common.C3	[256,128,1,False]
18	-1	1	147 712	models.common.Conv	[128,128,3,2]
19	[-1,14]	1	0	models.common.Concat	[1]
20	-1	1	296 448	models.common.C3	[256,256,1,False]
21	-1	1	590 336	models.common.Conv	[256,256,3,2]
22	[-1,10]	1	0	models.common.Concat	[1]
23	-1	1	1 182 720	models.common.C3	[512,512,1,False]
24	[17,20,23]	1	21 576	models.yolo.Detect	[3,[[0,1,2,3,4,5],[0,1,2,3,4,5],[0,1,2,3,4,5]], [128,256,512]]

注:L 表示网络层数;from 表示该层模块对应的输入层,-1 表示上一层,1 代表第 1 层,3 代表第 3 层,[-1,4]表示来自上一层和第 4 层的输入维度相加,[-1,6]、[-1,14]、[-1,10]类似,[17,20,23]表示第 17 层、第 20 层、第 21 层的输入维度相加;n 为模块数量,最终数量需要乘卷积通道缩放因子,然后四舍五入取整,如果小于 1 则取 1;module 为子模块名称;arguments 为模块参数;False 表示该层为预测端;'nearest'表示插值采样方式。

表 3 YOLOv5 超参数列表

序号	参数名称	初始值	序号	参数名称	初始值	序号	参数名称	初始值
1	lr0	0.01	11	obj	1.0	21	translate	0.1
2	lrf	0.01	12	obj_pw	1.0	22	scale	0.5
3	momentum	0.937	13	iou_t	0.2	23	shear	0.0
4	weight_decay	0.000 5	14	anchor_t	4.0	24	perspective	0.0
5	warmup_epochs	3.0	15	anchors	3.0	25	flipud	0.0
6	warmup_momentum	0.8	16	fl_gamma	0.0	26	fliplr	0.5
7	warmup_bias_lr	0.1	17	hsv_h	0.015	27	mosaic	1.0
8	box	0.05	18	hsv_s	0.7	28	mixup	0.0
9	cls	0.5	19	hsv_v	0.4	29	copy_paste	0.0
10	cls_pw	1.0	20	degrees	0.0			

法(Genetic Algorithm,GA),主要使用 90%的概率和 0.04 的方差的变异创造新后代,定义 fitness 函数对指标进行加权,迭代 300 次得到最优值。超参数(Hyp)优化原理见图 1。

YOLOv5 通过两种 Hyp 优化方法进行优化:一种是 Single 方式,即根据每个 Hyp 的权重随机选择一个作为基础值;另一种是 Weighted 方式,即根据每个 Hyp 的权重与前值进行融合得到一个基础值。每个 Hyp 的训练优化过程以一张图表显示,其中 Hyp 值在 x 轴上,Fitness 函数值在 y 轴上。超参数可视化见图 2、图 3。

2.3 优化效果

以 YOLOv5s 为框架,试验环境为 Python3.8+ Pytorch1.12.1、GPU 加速驱动 CUDA11.3,处理

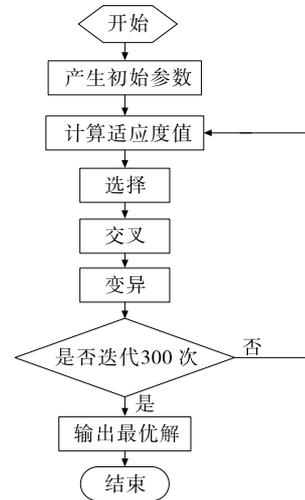


图 1 YOLOV5 超参数优化原理

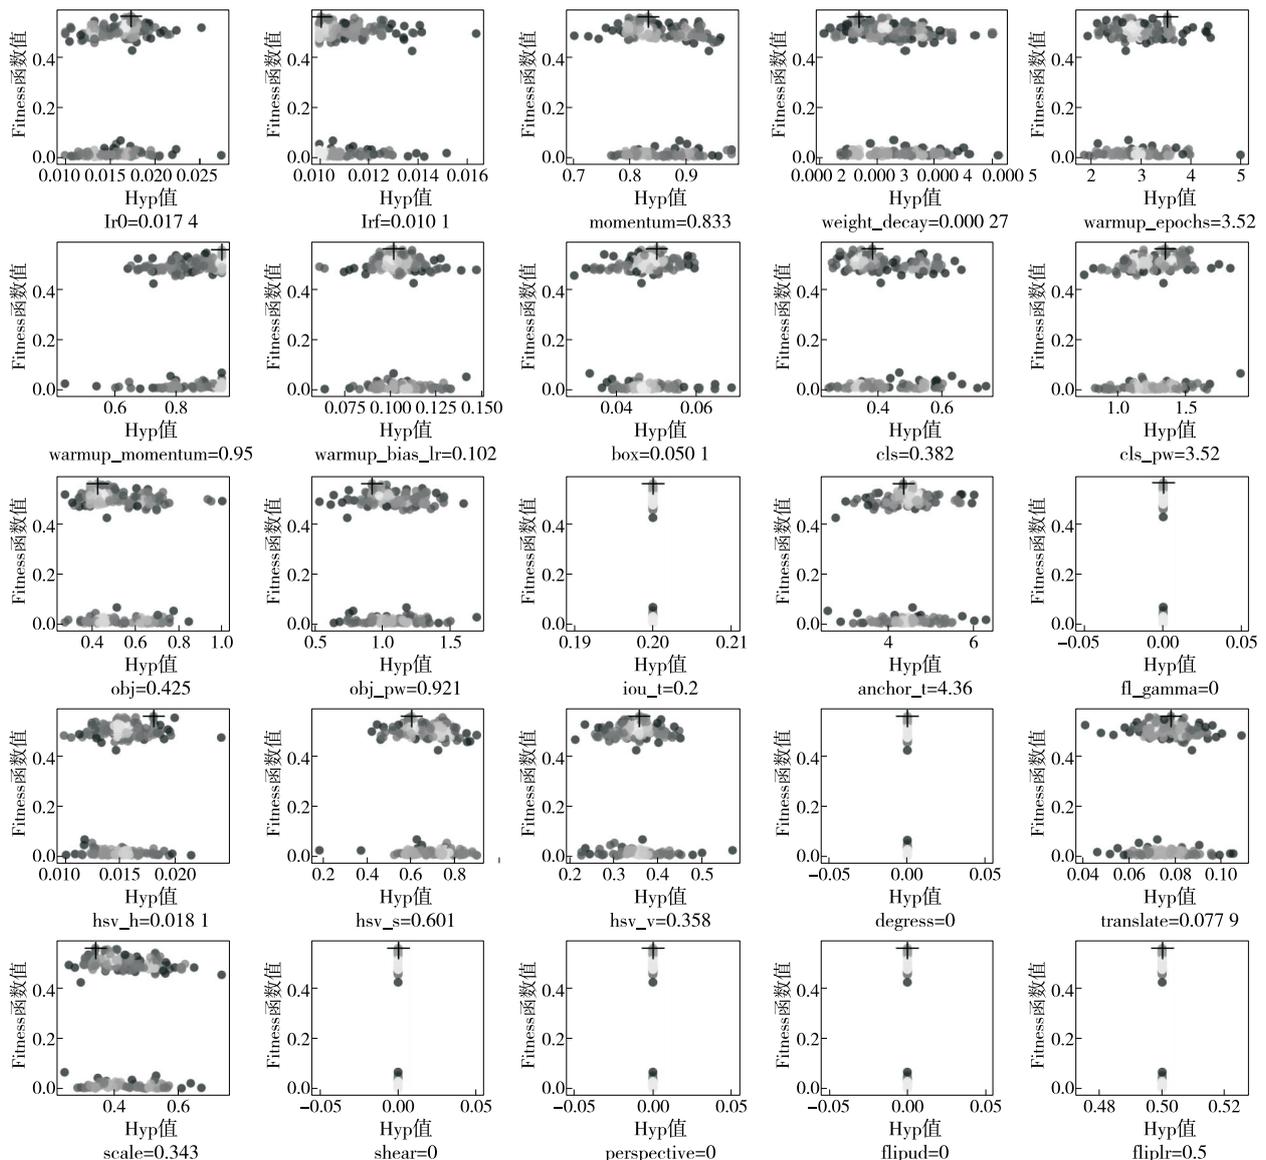


图 2 超参数优化可视化图一

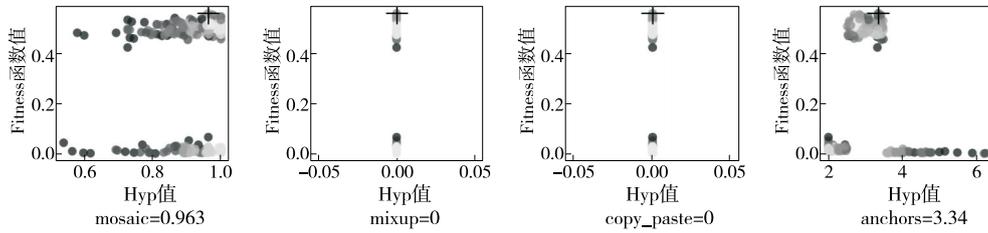


图 3 超参数优化可视化图二

器为 Intel (R) Core (TM) i7-6700HQ CPU @ 2.60 GHz,显卡为 NVIDIA GeForce GTX 960M。选用 coco2014 数据集作为训练数据,自定义轿车(car)、公交车(bus)、货车(truck)3 个类别,按照 7 : 3 的比例随机划分训练集和测试集,训练迭代次数为 300 次。参数优化效果见图 4。由图 4 可知:参数优化效果较明显,优化后算法对交通车辆的检测识别有较高的置信度,bus 由 0.83 提升到 0.97,car 从 0.85 到 0.95,整体提高 10%左右。

3 补光系统设计

3.1 交通规则相关要求

夏义红等对道路常亮型 LED 补光灯对驾驶人员视觉的影响进行试验,为减小其影响,提出补光强度应设置在 70 lx 以下,补光灯高度设置在距离地面 6 743 mm 处^[12]。GA/T 1202—2022《交通技术监控成像补光装置通用技术条件》对补光的相关规定见表 4^[13]。根据以上经验和规定,取补光灯高度



(a) 参数优化前检测识别



(b) 参数优化后检测识别

图 4 YOLOv5 算法参数优化前后对比

l 为 6 000~6 750 mm。补光装置的安装见图 5,安装高度与角度的关系见式(5)。

$$\alpha = \arctan(l/d) \tag{5}$$

要求 $60^\circ > \alpha > 30^\circ, 6\ 000\ \text{mm} < l < 6\ 750\ \text{mm}$, 由式(5)推算出补光区域长度 d 为 $4\ \text{m} < d < 12\ \text{m}$ 。

表 4 交通规则相关补光规定

道路情况	补光装置	光照度	补光区域	安装位置
照明不良道路	一级,频闪发光	沿行车方向、距离补光装置最远的过渡照明区域的环境光照度与补光区域补光装置的光照度之比大于 1 : 10、光照度 $\geq 8\ \text{lx}$	照明区域长度不小于补光区域长度 d 的 3 倍	补光装置安装在补光灯上方,与地面的垂直距离 $l > 6\ \text{m}$;补光装置基准轴与补光车道两条分界线所形成的空间角度 $\alpha \geq 30^\circ$
照明良好道路	频闪发光	最远的补光区域外的环境光照度与补光区域补光装置的光照度之比大于 1 : 10	—	

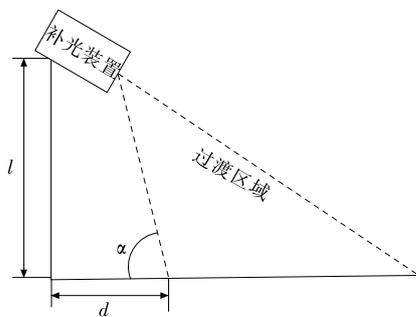


图 5 补光装置安装示意图

3.2 系统软硬件设计

补光系统由补光控制转台和补光装置伺服控制电机组成。补光控制转台的旋转和移动通过光电编码器实现。光电编码器除角度调节外,还可以捕获控制对象的位置信息,其数据处理功能强大,能满足车辆检测识别的需求^[11]。图 6 为系统硬件框图。

伺服控制电机选择基于 STM32 单片机实现电机驱动。STM32 单片机通过对光电编码器信号的处理控制补光装置的高度和角度,通过对光敏传感

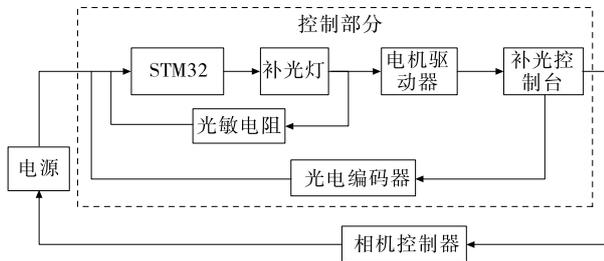


图 6 补光系统硬件框图

器信号的处理控制补光装置的光照强度,算法流程见图 7。该系统能提高夜间拍摄车辆图片的清晰度,保证车辆检测识别准确性。

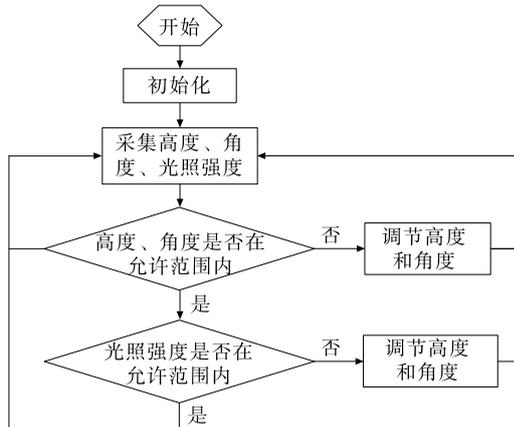


图 7 补光系统软件流程

3.3 系统调试

选择宁夏固原市各街道路口作为调试地点,在

不同天气状况下各拍摄 1 000 张图片,将拍摄质量较好图片的补光角度和光照强度参数记录下来进行整理,得到最佳补光参数(见表 5)。

表 5 补光装置参数汇总

拍摄天气	高度/mm	角度/(°)	补光区域/m	平均光照强度/lx
雨天	6 000	50	5	60
雾天	6 000	45	6	50
晴天	6 040	30	10	20

4 YOLOv5 的改进

4.1 颜色空间转换

YOLOv5 输入图像尺寸为 640 px×640 px×3 px,即长宽为 640 px×640 px 的三通道 RGB 彩色图片。RGB 颜色空间中 R、G、B 为三原色,即红色、绿色、蓝色,用一个正方体表示。本文采集的车辆图像利用夜间补光的方法拍摄而成,使用图像的亮度、饱和度等参数能更好、更直观地表达其拍摄质量,故采用 HSV 颜色空间进行图像处理。HSV 色彩空间以颜色的色调(H)、饱和度(S)、亮度(V)为三要素来表示,可以用一个立体的六面体来表示,是非线性颜色表示系统。RGB 到 HSV 色彩空间的转换原理见图 8。

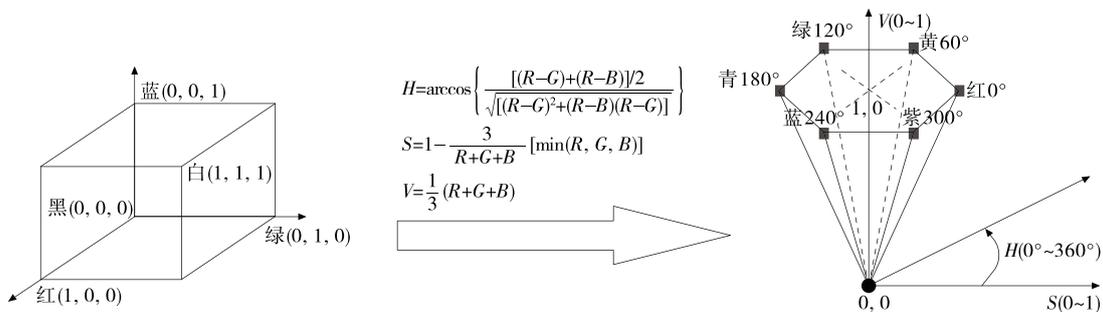


图 8 RGB 与 HSV 的空间转换关系

4.2 数据增强

设计两种基于 HSV 直方图曲线的数据增强方法。首先提取夜间不同天气补光拍摄图像的 HSV 直方图信息,再将其 H、S、V 参数进行数值变换,公式如下:

$$(H_i, S_i, V_i) = \Delta_i \cdot (H_{oi}, S_{oi}, V_{oi}) + b \quad (i=1, 2) \quad (6)$$

式中: H_i, S_i, V_i 表示增强图像的 HSV 值; Δ_i 为变换系数; H_{oi}, S_{oi}, V_{oi} 表示原图像的 HSV 值; $b=1$ 。

通过两种变换方法生成增强图像信息:第一种方法是线性变换,取(-1,1)之间的随机数进行倍数变换得到新的 HSV 直方图信息进行目标识别;第二种方法是利用高斯模型模拟图像的高斯分布,采用 Seaborn 库作出晴天、雨天和雾天的 HSV 直方图数据分布情况(见图 9)。根据数据分布定义高斯函数,规定均值 $\mu=100$ 、标准差 $\sigma=25$ 。公式如下:

$$\begin{cases} \Delta_1 = \text{rand}(-1, 1) \\ \Delta_2 = 1/(\sqrt{2\pi}\sigma) e^{-(x+1)^2/2} \end{cases} \quad (7)$$

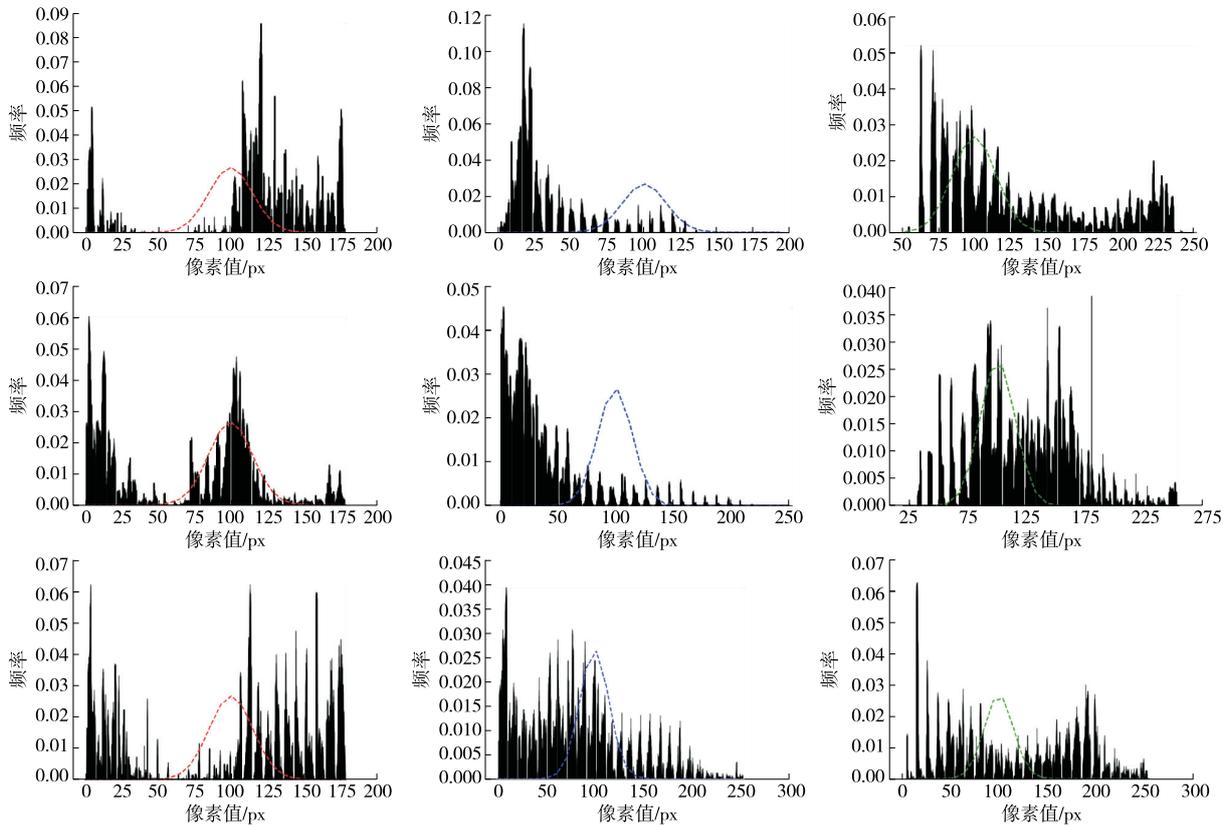


图 9 夜间图像 HSV 灰度直方图正态分布曲线

通过 MATLAB 模块得到图 9 中虚线所示每种天气对应图像的最佳正态分布曲线,不同天气直方图数据对应的高斯曲线中总方差见表 6。

采用两种方法得到的数据增强模型分别记为 YOLOv5-HSV1 和 YOLOv5-HSV2,晴天的数据增强效果见图 10、图 11,雾天的数据增强效果见图 12、图 13,雨天的数据增强效果见图 14、图 15。

表 6 高斯函数 σ 取值

天气	σ_H	σ_S	σ_V	天气	σ_H	σ_S	σ_V
晴天	1.0	1.0	1.4	雾天	1.0	0.7	1.0
雨天	1.0	1.0	3.0				

从图 10~15 可以看出两种 YOLOv5 数据增强方法能较清晰地呈现原图像。

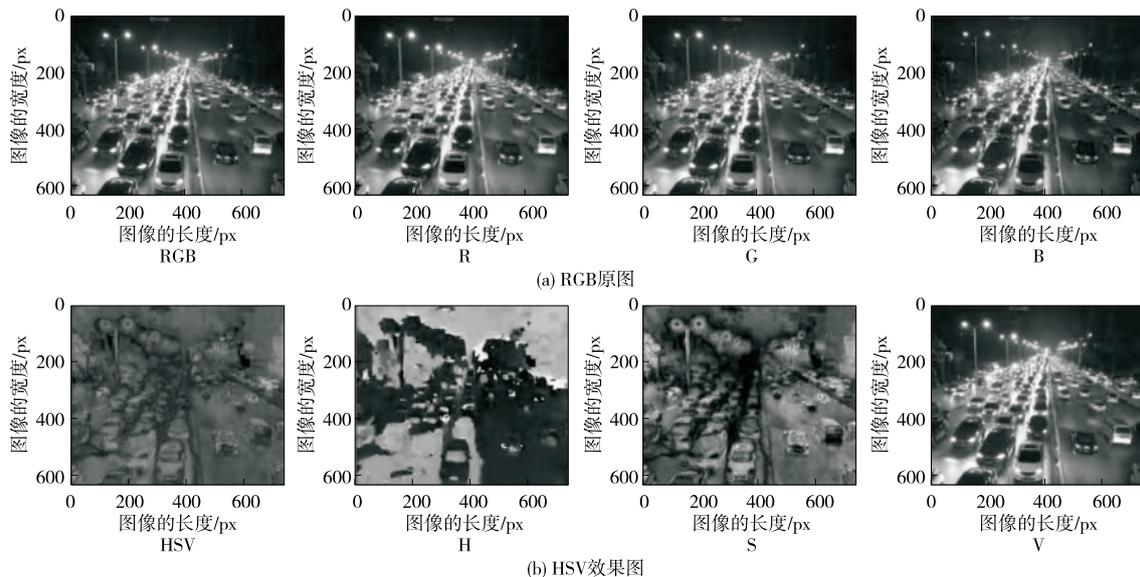
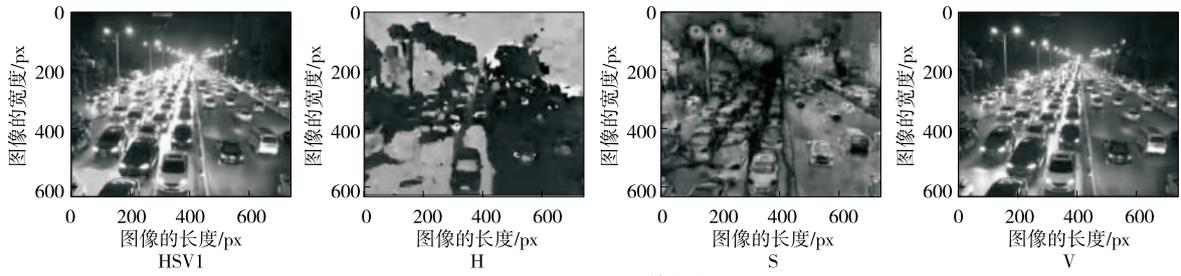
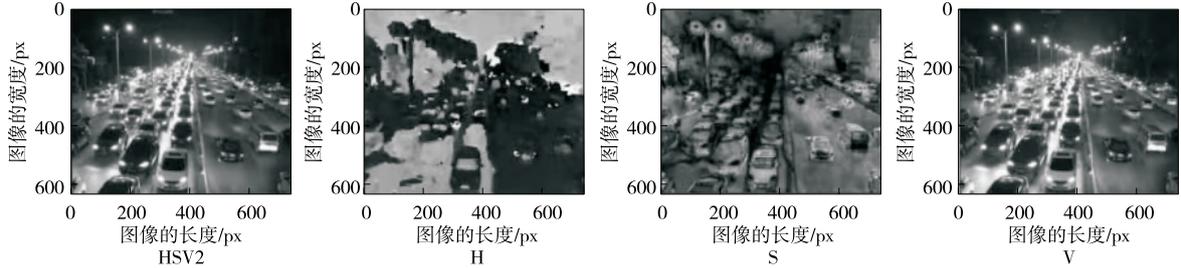


图 10 晴天的 RGB 原图和 HSV 效果图



(a) YOLOv5-HSV1效果图



(b) YOLOv5-HSV2效果图

图 11 晴天的 YOLOv5-HSV1 和 YOLOv5-HSV2 增强效果

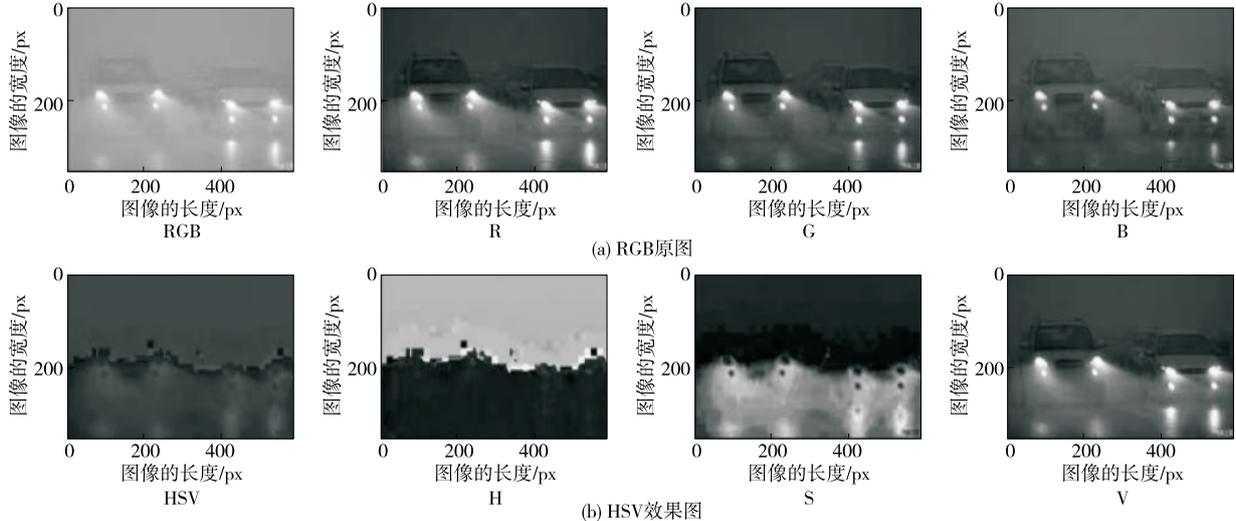


图 12 雾天的 RGB 原图和 HSV 效果图

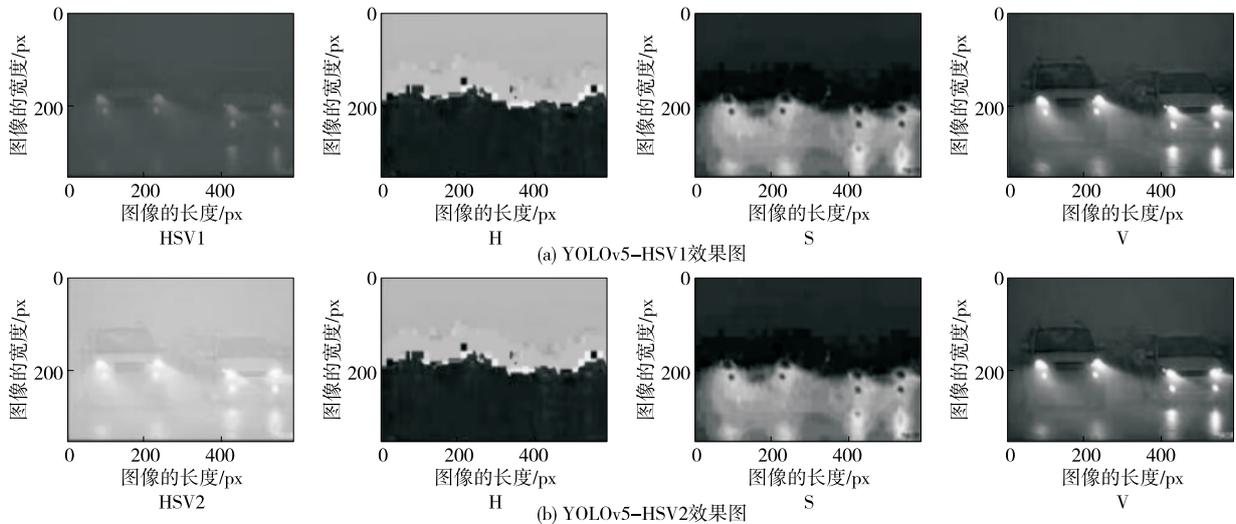


图 13 雾天的 YOLOv5-HSV1 和 YOLOv5-HSV2 增强效果

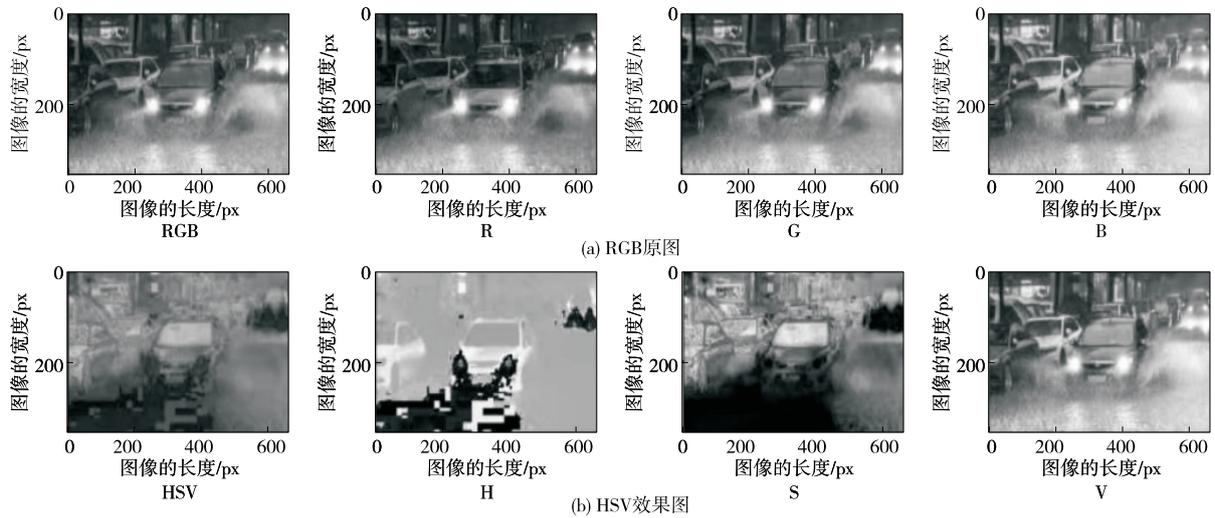


图 14 雨天的 RGB 原图和 HSV 效果图

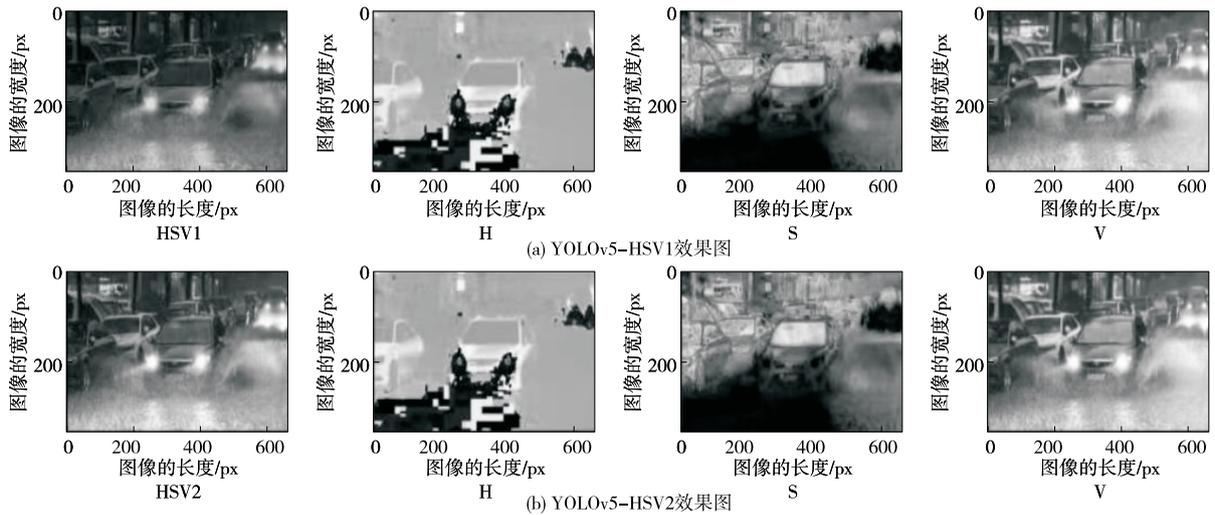


图 15 雨天的 YOLOv5-HSV1 和 YOLOv5-HSV2 增强效果

4.3 YOLOv5-HSV 空间模型

要获得一个表现良好的神经网络模型,往往需要大量数据作支撑。本文以 HSV 空间数据信息为基础设计一种数据增强技术,利用高斯函数生成数据,增加数据量,提高车辆目标检测准确度。对原有 YOLOv5 模型输入数据进行增强改进,通过 Backbone 层和 Neck 层提取图像特征。Backbone 层主要包括 Focus、CSP、SPP,其中 Focus 层最重要。Focus 层对输入的图片进行切片,由 Concat 层进行拼接,经过 CBL 层提取输入图片的各种特征信息,再通过 Batch Norm 层使每次计算的梯度在原点附近分布,从而使 Batch 的偏差较小,最后用 Leakyrelu 激活函数输入结果到下一层卷积。Neck 层是空间金字塔池化层,其作用是混合图像特征并将其传递到预测层。Prediction 层预测图像特征,生成边界框和预测类别。图 16 为模型框架。

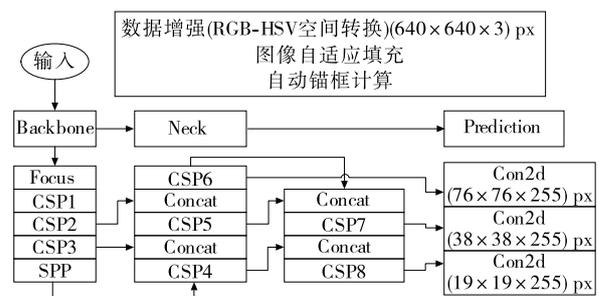


图 16 改进 YOLOv5 算法的结构框

5 试验与分析

5.1 数据集建立

基于深度学习的车辆检测方法需要从大量样本中学习车辆特征,若样本数据没有代表性,则很难训练出好的特征^[14-15]。本文自建数据集进行训练检测,试验样本数据采集于固原市各街道路口,摄像头

和补光灯支架安装位置和角度按表 5 取值。市区主要出现的车辆为轿车(car)、货车(truck)、公交车(bus)。为保证数据的多样性,分时间在相同路段进行图像采集,保证不同时段样本数据中具有不同的车型种类,其特征具有可比性^[16]。同时根据补光程度和拍摄角度,分别采集 3 组不同天气条件下样本数据,分别为正常天气车流、雨天车流、雾天车流。

为提高夜晚环境下车辆识别精度,删除车辆图像文件受损、相机聚焦不完全导致图像模糊等可能对检测算法识别造成干扰的图像。为提升整体模型的鲁棒性,在选择车辆图像时,着重选择一部分车辆相互遮挡的自然情况下的图像。对于选好的图像进行非线性数据增强,最终确定的试验数据集由市区数据集 6 016 张和 coco2014 网络数据集 500 张组成。模型训练过程中,按照 70%、30% 的比例将数据集随机分成训练集和验证集^[17-19],使用标注工具 LabelImg 分别进行人工标注,得到包含车辆的坐标信息 xml 文件。考虑到 YOLOv5 默认的标注文件类型为 txt 文件,通过 Python 编程将 xml 文件进行转化,以 txt 格式保存标注文件。txt 数据格式包括 class、x_center、y_center、width、height,其中 class 表示类别标签,其值为 0、1、2,x_center、y_center、width、height 已经过归一化处理。训练数据集分布见图 17。验证集包括两部分:一部分为是补光前的夜间车辆图片,总计 1 000 张,记为 Origin Test;另一部分为补光后的夜间车辆图片,总计 954 张,记为 Proposed Test。

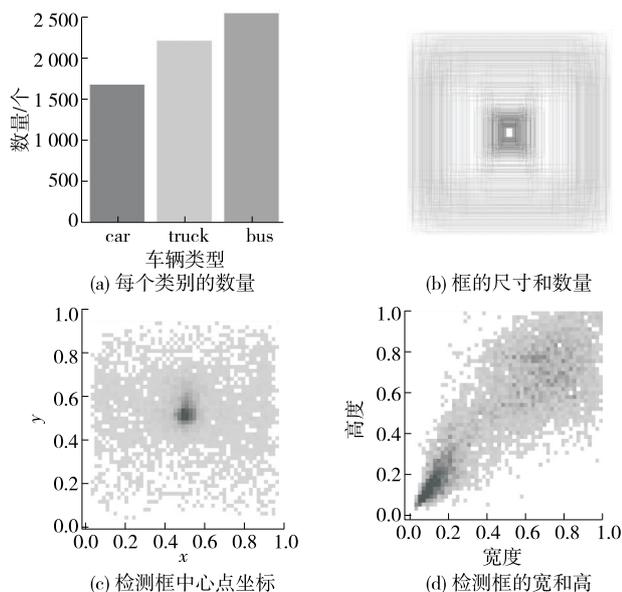


图 17 训练数据集分布

5.2 试验结果分析

对自建数据集的部分检测结果进行可视化,针对夜间天气情况分别进行晴天、雾天和雨天检测效果对比(见图 18)。由图 18 可知:由于夜间光线昏暗,原始 YOLOv5 算法对路上车辆的检测置信度不高,图中 1、2、3、4 处出现漏检情况;改进后算法没有出现漏检和误检情况。Proposed Test 数据集检测网络大幅度提高了车辆识别精度,降低了误检率和漏检率。

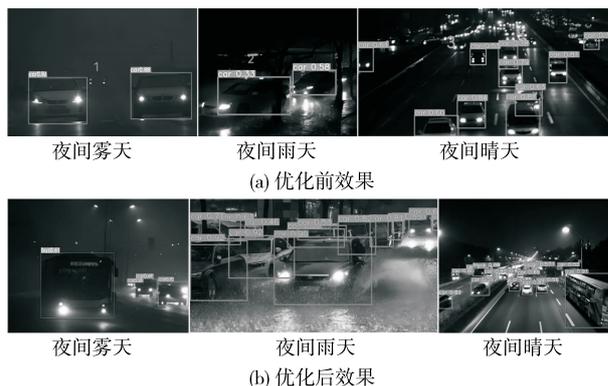


图 18 YOLOv5 算法改进前后不同数据集试验效果对比

采用原始 YOLOv5 算法在 Origin Test 模型上进行检测,采用改进 YOLOv5 算法在 Proposed Test 模型上进行检测,检测精度见表 7。由表 7 可知:与原始 YOLOv5 算法相比,采用改进 YOLOv5 算法,各类车辆检测识别精度均有所提升,car、truck、bus 分别提升 20.2%、4.3%、1.0%,整体精度 P_{mAP} (交并比为 0.50)提升 7.8%。

表 7 原始 YOLOv5 算法和改进 YOLOv5 算法的车辆检测识别精度对比

算法	各类车辆的识别精度			P_{mAP} (交并比为 0.50)
	car	truck	bus	
原始 YOLOv5 算法	0.827	0.954	0.985	0.922
改进 YOLOv5 算法	0.994	0.995	0.995	0.994

对数据集进行随机函数系数的数据增强,重复以上步骤进行分类训练,两种增强模型的性能见表 8。采用非线性化(高斯函数)数据增强方法,相比于随机函数线性化方法,车辆检测准确率提升 1.7%,召回率提高 1.4%,整体精度 P_{mAP} (交并比为 0.50)提升 4.4%, P_{mAP} (交并比为 0.50~0.95)提升 2.1%,检测帧速率 R_{FPS} 提升 14.3%。

表 8 两种增强模型的性能指标对比

增强模型	P	R	P_{mAP}		R_{FPS}
			交并比 为 0.50	交并比为 0.50~0.95	
YOLOv5-HSV1	0.964	0.899	0.952	0.871	56
YOLOv5-HSV2	0.980	0.912	0.994	0.889	64

6 结语

本文在 YOLOv5s 的基础上进行改进,采用自建车辆检测数据集,通过在训练过程中不断对参数进行优化,得到用于车辆实时检测的最优模型。由于夜间车辆图像受光线影响较大,在拍摄时自动调整补光强度,提高图像的可识别性。基于优质图像进行 HSV 方法非线性化数据增强,对 YOLOV5 训练结果有很大改善作用。根据试验结果,本文提出的检测方法在检测帧速率和检测精度方面都有明显提高,且能改善漏检率和误检率,车辆实时检测效果较好。该方法可用于夜间车辆数量统计,为交通灯时间合理分配提供依据,保证夜间道路的通畅和安全性。

参考文献:

- [1] 李杰,曾叙砚,孙领,等.全国道路交通安全水平的时空布局演化研究[J].中国安全科学学报,2021,31(12):136-143.
- [2] 马社强,丁立民,刘东,等.我国道路交通安全状况及挑战[J].中国人民公安大学学报(自然科学版),2020,26(4):35-41.
- [3] 南晓虎,丁雷.深度学习的典型目标检测算法综述[J].计算机应用研究,2020,37(增刊2):15-21.
- [4] 郭天鸿,刘海峰,张禹森,等.基于深度学习的车辆异常事件检测研究[J].现代交通技术,2023,20(5):71-77.
- [5] 李翠,李雪.基于车辆积压长度的高速公路交通事件检测算法[J].公路与汽运,2021(1):21-23+28.
- [6] 张威.基于 YOLOv4 的交通标志实时检测算法研究[D].北京:北京交通大学,2021.
- [7] 李德鑫.基于 YOLOv5s 的河道漂浮垃圾检测研究与应

用[D].徐州:中国矿业大学,2021.

- [8] 苏展.基于轻量化网络的遥感目标检测算法研究[D].西安:西安电子科技大学,2020.
- [9] 马永杰,马芸婷,程时升,等.基于改进 YOLOv3 模型与 Deep-SORT 算法的道路车辆检测方法[J].交通运输工程学报,2021,21(2):222-231.
- [10] 张漪,张美月.基于改进 YOLOv5 的交通监控视频车辆检测方法研究[J].内蒙古公路与运输,2022(2):50-55.
- [11] 方永锋,陶文亮,高榆兰.大数据条件下结构区间可靠性与概率可靠性比较[J].力学季刊,2020,41(3):582-589.
- [12] 夏义红,妮尔尔阿依·塔伊尔,毛思晴,等.道路常亮型 LED 补光灯对驾驶人员的视觉影响[J].中国安全生产科学技术,2021,17(5):176-181.
- [13] 公安部交通管理科学研究所,上海三思电子有限公司,杭州海康威视数字技术股份有限公司.交通技术监控成像补光装置通用技术条件:GA/T 1202—2022[S].北京:中国标准出版社,2022.
- [14] 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.
- [15] 牟亮,赵红,李燕,等.基于梯度压缩的 YOLOv4 算法车型识别[J].工程科学学报,2022,44(5):940-950.
- [16] 李珣,刘瑶,李鹏飞,等.基于 Darknet 框架下 YOLOv2 算法的车辆多目标检测方法[J].交通运输工程学报,2018,18(6):142-158.
- [17] 马丽萍,负鑫,马文哲,等.基于改进 YOLOv3 模型的道路车辆多目标检测方法[J].西安工程大学学报,2021,35(5):64-73.
- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [19] FENG J J, XU Z J, LIU Z. Improved YOLOv5 with attention mechanism for sar ship target detection in complex environment[J]. International Core Journal of Engineering, 2022(6): 0041-0046.

收稿日期:2023-11-07