

改进 Faster R-CNN 的交通标志检测算法

薛健,赵琳,张浩,杨璐,郝凡昌*

(山东建筑大学计算机科学与技术学院,山东 济南 250101)

摘要:针对目前交通标志检测方法受光照影响较大,模型精度低等问题,提出一种更快基于区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)的交通标志检测算法。针对图像中天空与非天空区域的光照不均匀现象,引入伽马变换增强交通标志在模型中的特征表达能力;利用基于卷积注意力模块的高效网络(convolutional block attention module-based an efficient network, CBAM-EfficientNet)解决网络深度退化问题,提高浅层网络的特征获取能力,降低参数量;在网络中引入特征金字塔网络以检测不同尺寸目标,增强网络对不同尺寸交通标志的感知能力,解决交通标志尺寸差异问题。试验结果表明,该算法在 GTSDb 数据集上的平均准确率均值 P_{mA} 达到 99.79%,在 CCTSDB2021 数据集上的 P_{mA} 达到 87.62%。为光照不均匀图像的交通标志检测提供一种高准确性的方法。

关键词:交通标志检测;Faster R-CNN;图像增强;特征金字塔网络;CBAM-EfficientNet

中图分类号:U463.6;TP391.41 **文献标志码:**A

引用格式:薛健,赵琳,张浩,等.改进 Faster R-CNN 的交通标志检测算法[J].山东大学学报(工学版),2024,54(5):34-41.

XUE Jian, ZHAO Lin, ZHANG Hao, et al. Traffic sign detection algorithm of improving Faster R-CNN[J]. Journal of Shandong University (Engineering Science), 2024, 54(5):34-41.

Traffic sign detection algorithm of improving Faster R-CNN

XUE Jian, ZHAO Lin, ZHANG Hao, YANG Lu, HAO Fanchang

(School of Computer Science and Technology, Shandong Jianzhu University, Jinan 250101, Shandong, China)

Abstract: To address the current limitations of illumination effects and low accuracy of model, a faster region-based convolutional neural network (Faster R-CNN) traffic sign detection algorithm was proposed. It addressed uneven illumination between sky and non-sky areas using Gamma transformation to improve the feature representation of traffic signs. The use of the convolutional block attention module-based an efficient network (CBAM-EfficientNet) counteracted network depth degradation, improved shallow network feature extraction and reduced parameters. The introduction of a feature pyramid network facilitated the detection of different-sized objects, enhanced the network's ability to perceive traffic signs of different sizes. Experimental results demonstrated high accuracy, with an P_{mA} of 99.79% on the GTSDb dataset and 87.62% on the CCTSDB2021 dataset, provided a highly accurate solution for the detection of unevenly illuminated traffic signs.

Keywords: traffic sign detection; Faster R-CNN; image enhancement; feature pyramid network; CBAM-EfficientNet

0 引言

近年来,随着人工智能技术的快速发展,智能驾驶正逐渐变为现实。为实现可靠的智能驾驶,系

统需要具备准确感知和理解道路环境的能力。交通标志作为传达交通规则、指引行驶方向和提供交通信息的重要元素,对驾驶人员起到重要的引导作用。在这一背景下,交通标志检测成为智能驾驶系统感知道路环境的关键组成部分。通过计算机视

收稿日期:2023-09-18

基金项目:山东省自然科学基金面上资助项目(ZR2022MF272);山东省高等学校青年创新团队资助项目(2022KJ205);山东省重点研发计划资助项目(2019GGX101068)

第一作者简介:薛健(1997—),男,山东菏泽人,硕士研究生,主要研究方向为机器学习与数据挖掘。E-mail: xuejian464@163.com

*通信作者简介:郝凡昌(1981—),男,山东济南人,副教授,硕士生导师,博士,主要研究方向为机器学习与数据挖掘方法及应用、算法分析与设计及应用。E-mail: haofanchang18@sdjzu.edu.cn

觉和人工智能技术可以实现道路交通标志自动检测,为智能驾驶提供决策数据。

根据特征设计方法,交通标志检测方法分为传统检测方法和基于深度学习的检测方法。传统检测方法主要通过各种手工提取的特征构建,例如通过颜色阈值分割^[1-2]、极大最稳定区域(maximally stable extremal regions, MSER)^[3]等特征获得感兴趣区域(region of interest, ROI),使用支持向量机(support vector machine, SVM)或卷积神经网络(convolutional neural network, CNN)等方法实现对 ROI 中交通标志的分类。但手工设计特征容易受光照不均、遮挡及运动模糊等因素的干扰,鲁棒性差,阈值需要人工先验知识的设计及调整,复杂度较高。基于深度学习的检测方法无需手工设计特征,可分为单阶段方法和两阶段方法。单阶段交通标志检测方法主要以 YOLO(you only look once)系列为主^[4-5],速度比两阶段方法快,但精度比两阶段方法低。两阶段交通标志检测方法主要以基于区域卷积神经网络(region-based convolutional neural network, R-CNN)系列为主^[6]。

光照不均匀现象是影响目标检测性能的一个重要因素,针对不均匀光照的处理显得尤为重要。文献[7]在进行刨花板表面缺陷检测时,引入结合伽马射线变换与图像差分处理方法,使图像中不均匀光照问题得到良好解决;文献[8]提出一种自适应图像增强算法,提高了模型在复杂光照条件下的检测性能;文献[9]对钢轨表面缺陷检测时,为解决图像光照较差的问题,将自适应伽马校正与限制对比度自适应直方图均衡化方法进行融合,实现对钢

轨表面缺陷细节的突出。

在目标检测任务中,由于目标尺寸不一致,单一特征图对不同尺寸目标进行检测会影响检测精度。文献[10]提出一种多区域生成网络(region proposal network, RPN)的更快基于区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)方法进行车辆检测,通过抽取特征提取网络中不同的特征图输入 RPN 层生成候选框,提高模型对不同尺寸车辆的检测能力。

在实际场景中,光照不均匀现象及交通标志尺寸不一致是影响交通标志检测准确性的2个主要问题,对模型的准确性和鲁棒性产生了较大影响。本研究在 Faster R-CNN^[11]基础上进行改进,提高交通标志检测模型的准确性和鲁棒性。通过伽马变换弥补光照不均匀带来的信息缺失问题;解决网络深度退化问题并提高浅层网络的特征获取能力,提出基于卷积注意力模块的高效网络(convolutional block attention module-based an efficient network, CBAM-EfficientNet);提高模型对图像中不同尺寸交通标志的检测能力,引入特征金字塔网络(feature pyramid network, FPN)^[12]。

1 Faster R-CNN 介绍

Faster R-CNN 是对 R-CNN^[13] 和 Fast R-CNN^[14] 算法的改进和扩展,结构如图 1 所示。相较于 R-CNN 和 Fast R-CNN, Faster R-CNN 引入了 RPN,用于自动生成图像中的候选区域。Faster R-CNN 的主要思想是将目标检测任务分解为 2 个子任务:候选区域生成、目标分类及边界框回归。




图 1 Faster R-CNN 模型结构
Fig.1 Structure of Faster R-CNN model

RPN 模型结构如图 2 所示,RPN 负责生成候选区域,以特征提取网络提取的特征图作为输入,在特征图的每个位点生成 3 个不同尺度的锚框。对于每个锚框,RPN 预测 2 个值:第一是锚框中是否包含目标物体,第二是对应目标物体的边界框回归值。

根据 RPN 的输出中预测存在物体的概率,选择

概率较高的一组锚框作为候选区域,将这些候选区域输入后续的 ROI 池化层中。ROI 池化层的主要功能是将不同大小的候选区域映射到固定大小的特征图,保持输入特征尺寸的一致性。这种固定大小的特征图可以输入后续的全连接层,进行目标分类和精确定位。




图2 RPN模型结构
Fig.2 RPN model structure

2 改进的 Faster R-CNN 网络

本研究在 Faster R-CNN 的基础上进行改进,提升目标检测性能。在图像输入模型时进行伽马变换,将特征提取网络更换为 CBAM-EfficientNet,引入 FPN 将不同尺度的特征图信息进行融合。改进后的 Faster R-CNN 模型结构如图 3 所示,其中 C 为特征提取网络的特征图,P 为 FPN 中的特征图,H 为原始图像的高度,W 为原始图像的宽度。

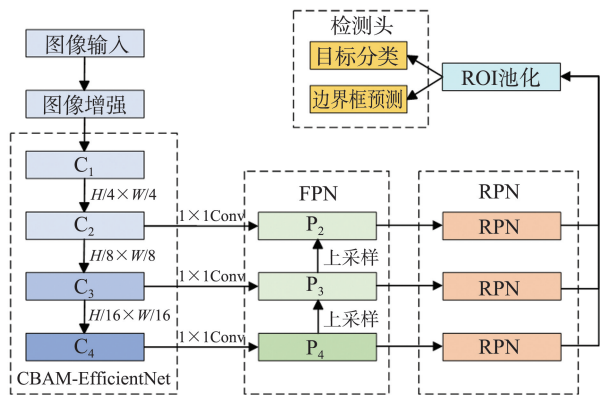


图3 改进后的 Faster R-CNN 模型结构
Fig.3 The improved structure of Faster R-CNN model

2.1 图像增强

在汽车行驶过程中采集的图像,天空区域非常明亮,非天空区域则相对暗淡。为解决这种光照不均匀问题,本研究尝试多种不同的图像增强方法,例如在亮度通道进行直方图均衡、分段伽马变换、log 变换等,通过对比后发现,伽马变换方法在增强交通标志特征表达能力方面拥有最出色的效果。将图像变换到 YUV 空间(Y 为亮度通道,可以看作灰度图像,仅表示亮度而不包含颜色信息;U、V 为色度通道,表示颜色差异),在 Y 通道进行伽马变换,将变换后的 Y 通道与 UV 通道合并,变换为

RGB 空间。这种处理有效增强了交通标志的特征表达能力,改善了模型检测性能。伽马变换前后对比如图 4 所示。



图4 伽马变换对比
Fig.4 Comparison of Gamma transform

将图像转换为 YUV 空间可以将亮度空间和颜色空间分隔开,在亮度空间进行操作时不会影响图像的色彩信息。

伽马变换是一种非线性变换,通过调整图像颜色通道的像素增强图像的对比度。经过伽马变换后的灰度输出

$$S = cr^\gamma, \quad (1)$$

式中: r 为像素点的输入,取值范围为 $[0, 1]$; c 为灰度缩放系数,通常取 1; γ 为伽马变换参数,用于控制灰度的调整程度,经过对比试验后设定 $\gamma = 0.4$ 。较小的 $\gamma (\gamma < 1)$ 经过伽马变换后增强低亮度部分,使图像更明亮;较大的 $\gamma (\gamma > 1)$ 经过伽马变换后增强高亮度部分,使图像更暗。 γ 越接近 1,变换后的图像亮度变化越小,越接近线性变换。

2.2 特征提取网络

2.2.1 EfficientNetV2

高效网络 (efficient network, EfficientNet) 是一种高效而强大的卷积神经网络架构^[15],通过神经网络搜索 (neural architecture search, NAS) 技术同时优化模型深度、宽度和图像分辨率,实现高效的模型缩放,在相对较小的参数量下能够达到较高的准确性,节约了计算资源和存储空间的消耗。EfficientNet 中移动翻转瓶颈卷积 (mobile inverted bottleneck convolution, MB Conv) 模块使用深度卷积 (depthwise convolution, Depthwise Conv), Depthwise Conv 通常比普通卷积 (convolution, Conv) 参数量少,在现有的硬件条件下,Depthwise Conv 的加速效果较差,导致 EfficientNet 训练速度较慢。

EfficientNetV2 是在 EfficientNet 的基础上进行改进的模型,主要解决 EfficientNet 训练速度较为缓慢的问题^[16]。EfficientNetV2 的模型结构和 MB Conv、融合移动翻转瓶颈卷积 (fused mobile inverted bottleneck convolution, Fused-MB Conv) 模

块如图 5 所示。EfficientNetV2 中, Fused-MB Conv 模块将 MB Conv 模块中的 Conv 1×1 和 Depthwise Conv 3×3 融合成 Conv 3×3 , 通道注意力机制 (SENet) 模块不变, 经过 NAS 技术确定将前 3 个 MB Conv 模块替换为 Fused-MB Conv 模块效果最佳。图像经过 MB Conv 及 Fused-MB Conv 特征提取模块后, 池化 (Pooling) 及全连接 (fully connected, FC) 输出结果。

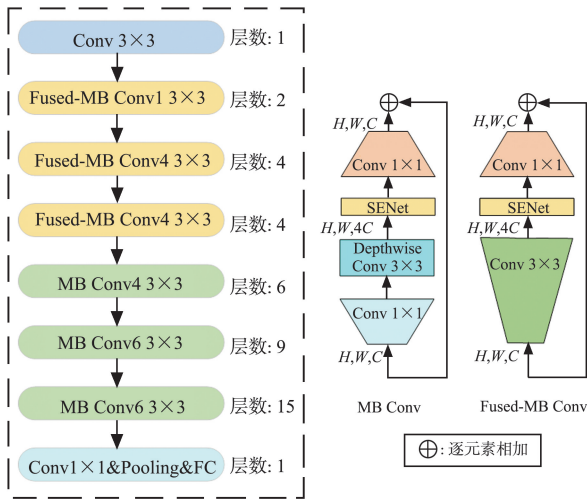


图 5 EfficientNetV2 模型结构
Fig.5 EfficientNetV2 model structure

2.2.2 卷积注意力模块

卷积注意力模块 (convolutional block attention module, CBAM) 通过引入通道注意力和空间注意力, 使网络能更好地聚焦于交通标志区域特征, 抑制非交通标志区域特征^[17]。CBAM 模块结构如图 6 所示。CBAM 包括 2 个独立的子模块: 通道注意力模块和空间注意力模块。特征图由卷积神经网络构建, 在 CBAM 中先计算通道注意力权重, 再计算空间注意力权重。将权重图与特征图相乘, 实现对图像中重要信息的关注。在交通标志检测任务中引入 CBAM 模块, 可提高形状及颜色等特征的代表能力, 提高网络的泛化能力, 抑制背景带来的干扰, 强化对交通标志区域的关注能力。




图 6 CBAM 模块结构
Fig.6 CBAM model structure

2.2.3 CBAM-EfficientNet

为提升模型在交通标志检测任务中的性能, 本研究对 EfficientNetV2 网络进行优化, 提出 CBAM-

EfficientNet 网络, 如图 7 所示。将 EfficientNetV2 网络尾部的 15 层 MBConv6 模块及相应的 Conv、Pooling 和 FC 替换为 CBAM 模块。CBAM 模块为网络引入通道注意力和空间注意力, 使网络能够更加聚焦于交通标志关键特征的学习和表示, 增强模型的感知能力, 更准确地捕捉交通标志的重要信息。

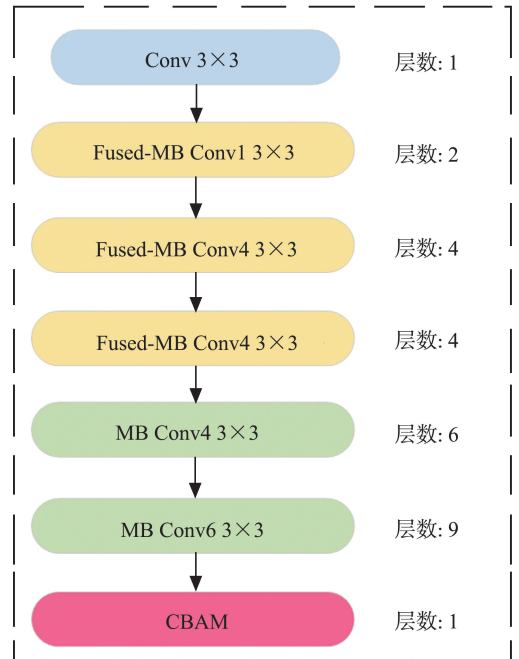


图 7 CBAM-EfficientNet 网络结构
Fig.7 CBAM-EfficientNet network architecture

本优化方法在保证模型检测对交通标志检测准确率的同时, 降低了网络深度, 减少了参数量, 对于计算资源有限的环境具有重要意义。

2.3 特征金字塔网络

受拍摄距离、角度等因素的影响, 不同图像中交通标志的尺寸不一致, 单层特征图的感受野有限, 影响不同尺度交通标志的检测能力。为增强对不同尺度交通标志的感知能力, 本研究引入 FPN 作为模型的一部分。

FPN 是一种用于处理不同尺度特征的卷积神经网络。传统的卷积神经网络中, 浅层网络提取的特征具有较大的尺寸、丰富的几何信息和较弱的语义信息, 适合目标定位; 深层网络提取的特征具有较小的尺寸、较少的几何信息和丰富的语义信息, 适合目标分类, 但不适合目标检测, 尤其是对小目标的检测。

FPN 结构如图 8 所示。图 8 左侧自下而上的路径通过卷积操作在较浅的特征图上进行特征提取, 获得更丰富的语义信息。该路径生成的特征图 C_2 、 C_3 、 C_4 的下采样率分别为 4、8、16 倍。为方便后续融合处理, 对特征图进行 1×1 的卷积操作, 将通道

数统一缩放到 256。图 8 右侧自上而下的路径进行上采样操作,将上采样后的深层特征图与浅层特征图相加,实现特征融合处理。这种融合处理有助于将来自不同尺度的特征信息相互补充,提高目标检测的性能。将融合后的特征图 P_2 、 P_3 、 P_4 输入后续的 RPN 中进行处理。




图 8 特征金字塔结构
Fig.8 FPN structure

3 试验与结果分析

3.1 试验数据集

德国交通标志检测数据集 (German traffic sign detection benchmark, GTSDB) 收集了德国 60 多个城市的道路场景,共包含 900 个不同时刻及天气状况的交通场景图像,其中训练集图像 600 张,验证集图像 300 张,图像大小为 1 360 像素 \times 800 像素^[18]。交通标志分为 4 类:禁止、危险、强制和其他。整个数据库中有 1 213 个交通标志,每张图像中有 0~6 个交通标志,每个交通标志的尺寸最小为 16 像素 \times 16 像素,最大为 128 像素 \times 128 像素。为增加数据集的多样性,通过随机裁剪、水平翻转、亮度变化等操作,将训练数据集扩充至 6 900 幅图像。

CCTSD2021 是长沙理工大学于 2022 年发布的中国交通标志检测基准^[19],包含 17 856 张不同天气及场景下的交通场景图像,交通标志分为禁止、警告和强制 3 类。训练集包含 16 356 张图像,包括 13 876 个禁止标志、4 598 个警告标志和 8 363

个强制标志;测试集由 1 500 张图像组成,有 3 228 个交通标志。

3.2 试验设置

试验采用深度学习框架 Pytorch, Python 版本 3.9, CUDA 版本 10.2, GPU 为 NVIDIA GeForce RTX 2080 Ti, 显卡内存 11 GB。

模型参数:试验中所有网络均使用 Pytorch 官方的预训练权重;随机梯度下降优化器,动量为 0.9,权重衰减为 0.000 1;初始学习率设置为 0.01,每 3 个迭代轮次将学习率调整为上一次的 0.33 倍;批量大小设置为 6,迭代次数设置为 50。

3.3 试验评价指标

为综合评价检测算法的性能,本研究选择目标检测任务中常用的评价指标平均准确率均值 P_{mA} 作为检测精度的衡量指标。 P_{mA} 是通过计算所有类别平均准确率 P_A 的均值得出。准确率 P 代表预测为真的标志中有多少实际为真,召回率 R 代表实际为真的例子中有多少被预测出来。 P 、 R 、 P_A 、 P_{mA} 的计算式分别为:

$$P = \frac{T_p}{T_p + F_p}, \quad (2)$$

$$R = \frac{T_p}{T_p + F_N}, \quad (3)$$

$$P_A = \int_0^1 P(R) dR, \quad (4)$$

$$P_{mA} = \frac{1}{C} \sum_{i=1}^C P_{Ai}, \quad (5)$$

式中: T_p 为正例被正确预测为正例的个数; F_p 为负例被错误预测为正例的个数; F_N 为正例被错误预测为负例的个数; C 为交通标志的类别数,本研究中 $C=4$ 。

3.4 GTSDB 数据集试验结果

3.4.1 消融试验

本试验比较了图像增强、特征提取网络、FPN 模块对检测精度的影响,试验结果如表 1 所示。

表 1 不同模块在 GTSDB 数据集上的消融试验

Table 1 Ablation experiments of different modules on the GTSDB dataset

特征提取网络	图像增强	FPN	$P_{mA}/\%$	参数量	推理速度/(帧 \cdot s ⁻¹)
Vgg16	×	×	89.44	29.45 \times 10 ⁶	15
Vgg16	✓	×	90.75	29.45 \times 10 ⁶	15
Vgg16	×	✓	96.67	31.33 \times 10 ⁶	12
Vgg16	✓	✓	97.71	31.33 \times 10 ⁶	12
EfficientNetV2	×	✓	99.55	37.45 \times 10 ⁶	13
EfficientNetV2	✓	✓	99.78	37.45 \times 10 ⁶	13
CBAM-EfficientNet	✓	✓	99.79	21.64\times10⁶	20

注:✓代表模型包含该模块,×代表未包含该模块。

在基础 FasterR-CNN 模型中分别引入图像增强及 FPN 模块后, P_{mA} 分别提高了 1.31、7.23 百分点,

同时增加图像增强和 FPN 模块后, P_{mA} 提高了 8.27 百分点。当特征提取网络更换为 EfficientNetV2 并

增加图像增强和 FPN 模块后,比 Vgg16 同样模块下的 P_{ma} 提高 2.07 百分点。当特征提取网络更换为 CBAM-EfficientNet 时, P_{ma} 相比 Vgg16 同样模块下提高 2.08 百分点,参数量减少了 31%,推理速度提升了 66%。上述消融试验证明了模型的有效性,模型在提升准确率和 FPS 的同时减少了参数量。

3.4.2 对比试验

为全面比较本研究提出的方法与其他研究方法的性能,将本研究提出的方法与 GTSDb 数据上的其他方法(包括改进掩码 R-CNN^[20]、改进 YOLOv3^[21]、改进单次多框检测(single shot multibox detector, SSD)^[22]、改进 YOLO^[23]、改进 Faster R-CNN^[24]、伪样本正则化 Faster R-CNN^[25])进行对比,试验结果如表 2 所示。由表 2 可以看出,相较于其他 6 种方法,本研究方法在 GTSDb 数据集上取得更好的检测结果。综上所述可知,本研究提出的方法可有效提升交通标志检测的精度。

表 2 不同研究方法在 GTSDb 数据集上的性能对比
Table 2 Performance comparison of different research methods on the GTSDb dataset

模型	特征提取网络	$P_{ma}/\%$
改进掩码 R-CNN ^[20]	ResNet101	96.16
改进 YOLOv3 ^[21]	DarkNet53	97.00
改进 SSD ^[22]	Vgg16	99.66
改进 YOLO ^[23]	ResNet50	97.21
改进 Faster R-CNN ^[24]	Vgg16	93.59
伪样本正则化 Faster R-CNN ^[25]	Vgg16	99.68
本研究提出方法	CBAM-EfficientNet	99.79

3.5 CCTSDB2021 数据集试验结果

为进一步证明模型的泛化能力及鲁棒性,将本研究提出的方法在 CCTSDB2021 数据集上进行试验,并与其他方法进行对比,结果如表 3 所示。由表 3 可以看出,本研究提出的方法在 CCTSDB2021 数据集上同样具有较好的性能。

表 3 不同研究方法在 CCTSDB2021 数据集上的性能对比
Table 3 Performance comparison of different research methods on the CCTSDB2021 dataset

模型	$P_{ma}/\%$
Faster R-CNN ^[19]	56.58
YOLOv3 ^[19]	50.48
SSD ^[19]	49.20
YOLOv5 ^[19]	76.30
改进 YOLOv5 ^[26]	78.40
改进 YOLOv5s ^[27]	82.00
本研究提出方法	87.62

3.6 试验结果可视化

为更加直观地呈现模型性能的提升,在 GTSDb 数据集上模型改进前后的对比结果如图 9、10 所示。图 9(a)(b)可以清晰地观察到未改进模型在光照不足区域漏检交通标志,改进后的模型不仅能够检测到交通标志的存在,同时提高了原始模型检测结果的置信度。图 9(c)~(f)中改进后的模型对目标的置信度有较大提升。这些可视化检测结果充分证明了模型改进的显著效果。图 10 为图 9 中 3 组图像的局部细节,这些细节通常难以被人眼观察到,通过本研究提出的模型能够将其准确地检测出来,进一步证明了模型的出色性能。

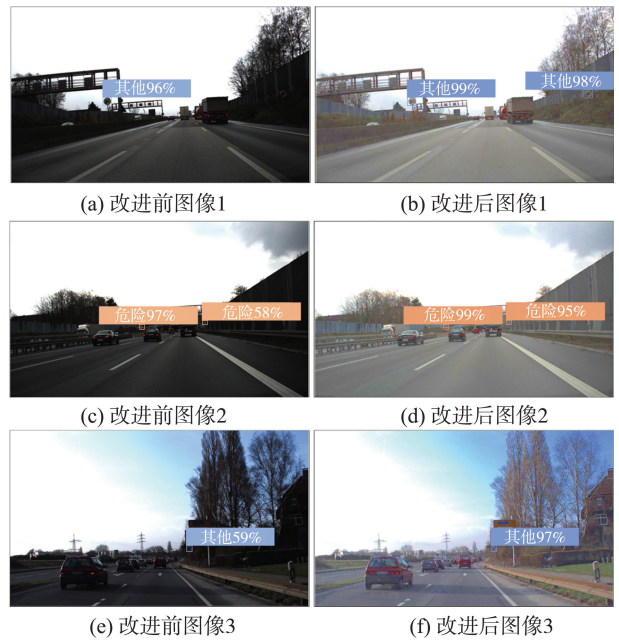


图 9 不同模型的检测结果图像

Fig.9 Images of detection results of different models



图 10 不同模型检测结果的局部图像

Fig.10 Local images of detection results of different models

4 结论

本研究提出一种改进 FasterR-CNN 的交通标志检测方法。为减少图像中光照不均匀问题,在图像输入模型时对图像进行增强,增加交通标志区域的特征表达能力。提出 CBAM-EfficientNet 作为特征提取网络,改善模型的特征提取能力,降低模型的参数量。针对不同角度、距离拍摄图像中交通标志尺寸不一致问题,引入特征金字塔网络,将浅层网络提取的丰富几何信息特征与深层网络提取的丰富语义信息特征融合,增强对不同尺寸交通标志的感知能力,提升模型的检测能力。

参考文献:

- [1] HECHRI A, MTIBAA A. Two-stage traffic sign detection and recognition based on SVM and convolutional neural networks [J]. *Iet Image Processing*, 2020, 14 (5): 939-946.
- [2] XU X H, JIN J C, ZHANG S Q, et al. Smart data driven traffic sign detection method based on adaptive color threshold and shape symmetry[J]. *Future Generation Computer Systems-the International Journal of Escience*, 2019, 94: 381-391.
- [3] SHAO F M, WANG X Q, MENG F J, et al. Improved Faster R-CNN traffic sign detection based on a second region of interest and highly possible regions proposal network[J]. *Sensors*, 2019, 19(10): 2288.
- [4] YU J, YE X J, TU Q. Traffic sign detection and recognition in multi images using a fusion model with YOLO and VGG network [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23 (9): 16632-16642.
- [5] LIU Y C, SHI G, LI Y X, et al. M-YOLO: traffic sign detection algorithm applicable to complex scenarios [J]. *Symmetry-Basel*, 2022, 14(5): 952.
- [6] ZHANG J M, XIE Z P, SUN J, et al. A cascaded R-CNN with multiscale attention and imbalanced samples for traffic sign detection[J]. *IEEE Access*, 2020, 8: 29742-29754.
- [7] ZHAO Z Y, YANG X X, ZHOU Y C, et al. Real-time detection of particleboard surface defects based on improved YOLOV5 target detection[J]. *Scientific Reports*, 2021, 11(1): 21777.
- [8] YAN Y, DENG C, MA J J, et al. A traffic sign recognition method under complex illumination conditions [J]. *IEEE Access*, 2023, 11: 39185-39196.
- [9] ZHANG C G, XU D L, ZHANG L F, et al. Rail surface defect detection based on image enhancement and improved YOLOX[J]. *Electronics*, 2023, 12(12): 2672.
- [10] GHOSH R. On-road vehicle detection in varying weather conditions using Faster R-CNN with several region proposal networks[J]. *Multimedia Tools and Applications*, 2021, 80(17): 25985-25999.
- [11] 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.
- [12] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//*Proceedings of the 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, USA: IEEE, 2017: 936-944.
- [13] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Columbus, USA: IEEE, 2014: 580-587.
- [14] GIRSHICK R. Fast R-CNN [C]//*Proceedings of the Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. Boston, USA: IEEE, 2015: 1440-1448.
- [15] TAN M, LE Q. Efficientnet: rethinking model scaling for convolutional neural networks [C]//*Proceedings of the International Conference on Machine Learning*. Long Beach, USA: PMLR, 2019: 6105-6114.
- [16] TAN M, LE Q. EfficientNetV2: smaller models and faster training [C]//*Proceedings of the International Conference on Machine Learning*. [S.l.]: PMLR, 2021: 10096-10106.
- [17] WOO S H, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//*Proceedings of the 15th European Conference on Computer Vision (ECCV)*. Munich, Germany: Springer, 2018: 3-19.
- [18] HOUBEN S, STALLKAMP J, SALMEN J, et al. Detection of traffic signs in real-world images: the German traffic sign detection benchmark[C]//*Proceedings of the International Joint Conference on Neural Networks (IJCNN)*. Dallas, USA: IEEE, 2013: 1-8.
- [19] ZHANG J M, ZOU X, KUANG L D, et al. CCTSDB2021: a more comprehensive traffic sign detection benchmark[J]. *Human-Centric Computing and*

- Information Sciences, 2022, 12: 23.
- [20] SERNA C G, RUICHEK Y. Traffic signs detection and classification for European urban environments[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(10): 4388-4399.
- [21] ZHANG J M, YE Z, JIN X K, et al. Real-time traffic sign detection based on multiscale attention and spatial information aggregator[J]. Journal of Real-Time Image Processing, 2022, 19(6): 1155-1167.
- [22] LEE H S, KIM K. Simultaneous traffic sign detection and boundary estimation using convolutional neural network [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(5): 1652-1663.
- [23] WEI H Y, ZHANG Q Q, LI X, et al. YOLOF-F: you only look one-level feature fusion for traffic sign detection[J]. Visual Computer, 2023, 39(3): 1-14.
- [24] WANG W, WU B, LÜ J, et al. Regular and small target detection [C]//Multi Media Modeling: 25th International Conference (MMM). Thessaloniki, Greece: Springer, 2019: 453-464.
- [25] 李厚杰,王法胜,贺建军,等. 基于伪样本正则化 Faster R-CNN 的交通标志检测[J]. 吉林大学学报(工学版), 2021, 51(4): 1251-1260.
- LI Houjie, WANG Fasheng, HE Jianjun, et al. Pseudo sample regularization Faster R-CNN for traffic sign detection[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(4): 1251-1260.
- [26] 李翔宇,王倩影. 基于改进 YOLOv5 的复杂背景下交通标志识别研究[J]. 现代信息科技, 2023, 7(10): 30-32.
- LI Xiangyu, WANG Qianying. Research on traffic sign recognition in complex background based on improved YOLOv5[J]. Modern Information Technology, 2023, 7(10): 30-32.
- [27] WANG Q Y, LI X Y, LU M. An improved traffic sign detection and recognition deep model based on YOLOv5 [J]. IEEE Access, 2023, 11: 54679-54691.
- (编辑:孙亚彤)

(上接第33页)

- [18] CHEN C, LIANG J, XIE F, et al. Temporal and spatial variation of coastline using remote sensing images for Zhoushan Aarchipelago, China[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 107: 102711.
- [19] SATHE Y, KULKARNI S, GUPTA P, et al. Application of moderate resolution imaging spectroradiometer (MODIS) aerosol optical depth (AOD) and weather research forecasting (WRF) model meteorological data for assessment of fine particulate matter ($PM_{2.5}$) over India[J]. Atmospheric Pollution Research, 2019, 10(2): 418-434.
- [20] 徐少才,王静,吴建会,等. 青岛市 $PM_{2.5}$ 化学组分特征及综合来源解析[J]. 中国环境监测, 2018, 34(4): 44-53.
- XU Shaocai, WANG Jing, WU Jianhui, et al. Characterization of chemical composition and comprehensive source apportionment of $PM_{2.5}$ in Qingdao [J]. Environmental Monitoring in China, 2018, 34(4): 44-53.
- [21] 百度地图,2022 年度中国城市交通报告[R]. 百度地图, 2023. <https://jiaotong.baidu.com/reports/>.
- (编辑:郭少华)