

徐润权,张林俊,张靖佳,等.基于改进 SSD 模型的道路交通标志识别方法[J].湖南科技大学学报(自然科学版),2024,39(2):87-96.doi:10.13582/j.cnki.1672-9102.2024.02.011

XU R Q, ZHANG L J, ZHANG J J, et al. Recognition Method of Road Traffic Signs Based on Improved SSD Model[J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2024, 39(2): 87-96. doi: 10.13582/j.cnki.1672-9102.2024.02.011

基于改进 SSD 模型的道路交通标志识别方法

徐润权¹,张林俊¹,张靖佳¹,许恩永²,何水龙^{1,2*}

(1.桂林电子科技大学 机电工程学院,广西 桂林 541004;2.东风柳州汽车有限公司 技术中心,广西 柳州 545005)

摘要:为了帮助智能汽车快速识别前方的交通标志,提升汽车在交通道路上的行驶安全,针对现有技术在识别过程中容易出现误检和漏检的问题,在优化现有 SSD(Single Shot MultiBox Detector)目标检测模型的基础上,提出一种新的检测模型 Rep-SSD(Re-parametrization, SSD),保证网络的实时性和识别的准确性.为增强骨干网络的特征提取能力,将 SSD 骨干网络中的卷积层更换为重参数化卷积层,在训练过程加入多分支结构增强网络特征的提取能力,在推理过程中采用重参数化技术简化网络,保持网络的识别速度.为进一步增强改进网络的小目标识别能力,加入 CBAM(Convolutional Block Attention Module)注意力机制,强化网络提取到的特征信息.试验结果表明:在德国交通标志识别数据集 GTSRB 上,Rep-SSD 模型的检测精度达到 84.7%,检测速度(FPS)达到 110 帧每秒,模型具有较好的检测精度和实时性.所提出的 Rep-SSD 模型为自动驾驶汽车提供了一种实时且准确的交通标志识别方案.

关键词:交通标志牌识别;目标检测;重参数化卷积;CBAM 注意力机制

中图分类号:TP391.41;U463.6 **文献标志码:**A **文章编号:**1672-9102(2024)02-0087-10

Recognition Method of Road Traffic Signs Based on Improved SSD Model

XU Runquan¹, ZHANG Linjun¹, ZHANG Jingjia¹, XU Enyong², HE Shuilong^{1,2}

(1. School of Mechanical and Electrical Engineering, Guilin University of Electronic Technology, Guilin 541004, China;

2. Department of Technology Center, Dongfeng Liuzhou Motor Co., Ltd., Liuzhou 545005, China)

Abstract: In order to assist intelligent vehicles in identifying ahead traffic signs rapidly and enhancing the safety of vehicle travel on roads, addressing the issues of misidentification and omission prone to occur in existing technologies during the recognition process, a new detection model, Rep-SSD (Re-parametrization SSD) is proposed based on optimizing the existing SSD (Single Shot MultiBox Detector) object detection model to ensure real-time performance and recognition accuracy. To enhance the feature extraction capability of the backbone network, the convolutional layers in the SSD backbone network are replaced with re-parametrization convolutional layers. A multi-branch structure is incorporated during training to enhance the network's feature extraction capability, and re-parametrization techniques are employed during inference to simplify the network while maintaining recognition speed. To further enhance the small object recognition capability of the improved network, the CBAM (Convolutional Block Attention Module) attention mechanism is introduced to reinforce the feature information extracted by the network. Experimental results demonstrate that on the German Traffic Sign Recognition Benchmark (GTSRB) dataset, the detection accuracy of the Rep-SSD model reaches 84.7%, with a

收稿日期:2022-10-14

修改日期:2024-04-29

基金项目:广西创新驱动发展专项资助项目(AA22068001;AA23062031);广西重点研发计划资助项目(AB21196029);柳州市科技计划资助项目(2022AAA0102)

*通信作者,E-mail: xiaofeilonghe@163.com

detection speed of 110 frames per second, indicating it has good detection accuracy and real-time performance. The proposed Rep-SSD model provides a real-time and accurate solution for traffic sign recognition in autonomous driving vehicles.

Keywords: traffic sign recognition; object detection; re-parametrization convolution; CBAM attention mechanism

随着车辆保有量的增加和人工智能学科的发展,自动驾驶技术得到广泛的关注,成为当前汽车技术领域研究的热点.从环境感知到路径规划和轨迹跟踪,许多学者对自动驾驶领域的关键技术进行了研究^[1].环境感知技术作为自动驾驶技术的基础,汽车主要依赖其获取车辆周边以及道路上的信息,包括行人、车辆、车道线以及交通标志牌等信息^[2].交通标志牌作为道路上不可或缺的一部分,具有丰富的语义信息,有禁止标志、警示标志和指示标志等.目标识别是一项非常重要且具有挑战性的工作,真实目标的识别近年来也得到许多学者的关注^[3-6].在现实道路环境进行交通标志牌识别的过程中,汽车不仅要获取交通标志牌的位置,而且还要判断对应标志的语义信息.现阶段交通标志牌识别算法主要分为2类:传统交通标志牌识别和基于深度学习的交通标志牌识别^[7].

传统交通标志牌识别主要基于模式匹配或颜色特征进行识别,需要通过人工构建特征来辅助算法进行识别.GAVRILA^[8]基于距离变换的模板匹配实现形状检测,并将其应用于交通标志牌识别;PICCIOLI等^[9]对输入图像进行边缘几何分析生成特定形状的候选框来进行模式匹配;许少秋^[10]利用边缘信息提取交通标志牌的外部形状,在正切空间中采用模板匹配实现对交通标志牌的形状识别;朱双东等^[11]构建基于颜色形状对的几何模型来匹配对应的交通标志牌;CREUSEN等^[12]基于颜色转换来扩展基于定向梯度的直方图,以此提高交通标志牌识别的准确率;MADANI等^[13]利用输入图像的颜色、边界形状等信息对交通标志牌进行匹配识别;赵宏伟等^[14]利用特征融合,将颜色特征和形状特征进行融合,提出用于检测交通标志牌图像的快速检索算法.

基于深度学习的交通标志牌识别主要利用深度学习算法对图片进行特征提取与学习,主流的算法框架可分为单阶段检测网络和两阶段检测网络^[15].单阶段检测网络主流有YOLO(You Only Look Once)系列^[16-21]以及SSD(Single Shot MultiBox Detector)^[22]等.DEWI等^[23]将空间金字塔嵌入YOLOv4模型中,提出用于交通标志牌检测的增强网络模型;潘卫国等^[24]直接将YOLOv3应用在交通标志牌识别上;江金洪等^[25]将深度可分离卷积引入YOLOv3模型,并使用广义交叉比损失函数替换均方误差损失函数,可以同时提升模型的检测速度与检测精度;郭继峰等^[26]对YOLOv4-Tiny进行优化,通过深度可分离卷积降低网络的参数量和计算量;李志刚等^[27]引入Stem模块和ShuffleNetV2来替换YOLOv5的主干网络,提出轻量化的YOLOv5网络.两阶段检测网络主流有区域卷积神经网络(R-CNN)^[28]和Faster R-CNN^[29]等.邓天民等^[30]基于卷积神经网络,结合空间金字塔结构和批量归一化技术,提出改进空间金字塔池化卷积神经网络(SPPN-CNN)模型用于交通标志牌识别;SERMANET等^[31]提出将多尺度卷积神经网络应用于交通标志牌识别;CHENG等^[32]提出基于局部区域的Faster R-CNN用于检测小目标交通标志牌;徐国整等^[33]将R-CNN进行优化,提出Cascade R-CNN用于交通标志牌识别;王海等^[34]将特征图像金字塔模块的特征信息融入Cascade R-CNN,以此提升原有网络对小目标交通标志牌识别的准确率.单阶段检测网络直接对输入数据进行特征提取来实现目标检测,识别效率高但识别精度低.两阶段检测网络则需要先生成候选框,然后利用算法对生成的候选框进行分类检测,识别精度高但是识别效率低.

在识别交通标志牌时,由于交通标志牌在图片中的占比较小,所以要求交通标志牌识别算法能够较好地识别出小目标,并且要求具有一定的实时性^[35-37].SSD目标检测算法借鉴Faster R-CNN的锚框机制,并去除Faster R-CNN生成候选框的步骤,可以提高网络的运行速度,利用多尺度特征检测网络提取特征来保证网络的检测精度,使网络既具有一定的实时性也具备较好的识别精度.

在应用SSD目标检测算法进行交通标志牌识别时,由于该算法模型在提取小目标特征的浅层特征层语义信息的不足,导致算法仍然会存在误检和漏检等问题.田智慧等^[38-39]对SSD算法网络进行优化,虽然提高了精度,但是同时也牺牲了一定的检测速度.

针对该问题,本文通过优化SSD目标检测算法模型,提出一种新的交通标志牌识别模型Rep-SSD(Re-

parametrization SSD).首先对数据集进行数据增强处理,然后将 SSD 模型的骨干网络 VGG-16 (Visual Geometry Group-16)^[40] 中的卷积层更换为重参数化卷积层 (Re-parametrization Convolution, RepConv),增强骨干网络的特征提取能力,并在多尺度特征提取网络前嵌入 CBAM (Convolutional Block Attention Module) 注意力机制,使网络在提取特征时能够更加关注通道和空间 2 个维度,更好地识别小目标.

1 SSD 目标检测算法模型

SSD 目标检测算法是单阶段检测算法的典型代表之一,采用 VGG-16 作为骨干网络,在 VGG-16 的基础上,去除最后的全连接层,将第 6 层和第 7 层的全连接层替换为 3×3 的卷积网络和 1×1 的卷积层,并在骨干网络之后添加 4 层卷积层用于多尺度特征提取.

SSD 目标检测模型包含 6 层多尺度特征提取层,每层的特征提取层分别对位置 loc 和类别 conf 进行卷积,得到相应的有效特征.最后使用极大值抑制算法输出最终的检测结果,实现目标的定位与分类.随着层数的增加,特征图的尺寸逐渐减小,使模型能够更好地检测各种尺寸的目标.SSD 的网络结构如图 1 所示.

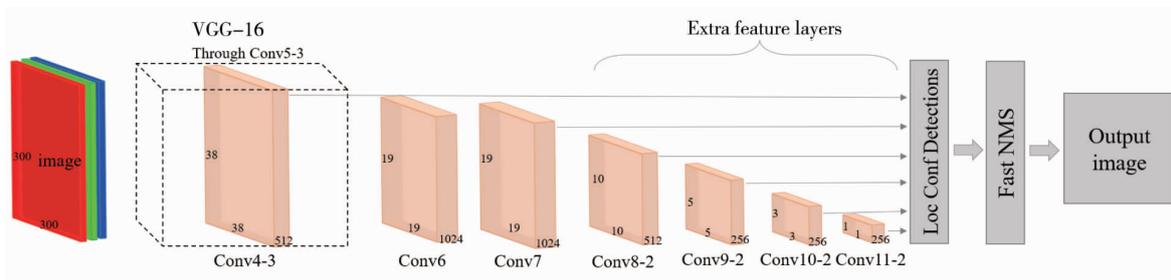


图 1 SSD 网络结构

在 SSD 目标检测模型中,较低层次的特征提取层获取的特征图的尺寸较大,相应生成的锚框尺寸较小,数量较多,更适合用于检测小目标.而较高层次的特征提取层所获取的特征图的尺寸较小,相应生成的锚框尺寸较大,数量较少,主要用于检测大目标.SSD 目标检测模型中用于检测小目标的特征提取层主要来自 VGG-16 中的 Conv4-3 层,该层的语义信息不够丰富,在进行交通标志牌识别时的效果并不是很理想.

2 Rep-SSD 目标检测算法模型

在交通标志牌识别中,由于车辆与交通标志牌的距离较远,拍摄到的图像中交通标志的占比较小,容易导致算法识别时出现误检和漏检等问题^[41].因此,应用于自动驾驶领域的算法要求具备一定的实时性与准确性.作为单阶段检测网络,SSD 目标检测模型要求输入图片的分辨率满足 300×300 或者 512×512 的小尺寸,这样才能保证该模型在交通标识牌识别时具有更好的识别效果.

SSD 目标检测模型在算法设计上考虑小目标的识别,使用多尺度特征图来适配各种尺度的目标检测.然而,由于负责小目标检测的浅层特征层 Conv4-3 所输出的特征信息较为简单,应用在交通标志牌识别时仍存在的问题.为解决上述问题,本文基于 SSD 目标检测网络提出一种新的检测模型 Rep-SSD.首先,将 SSD 模型的骨干网络 VGG-16 的卷积层替换为重参数化卷积模块,丰富原有网络的浅层特征;然后,在原有模型的多尺度特征提取层前嵌入 CBAM 注意力机制,增强网络对目标区域的关注.Rep-SSD 的网络结构如图 2 所示,Rep-SSD 的核心参数如表 1 所示.

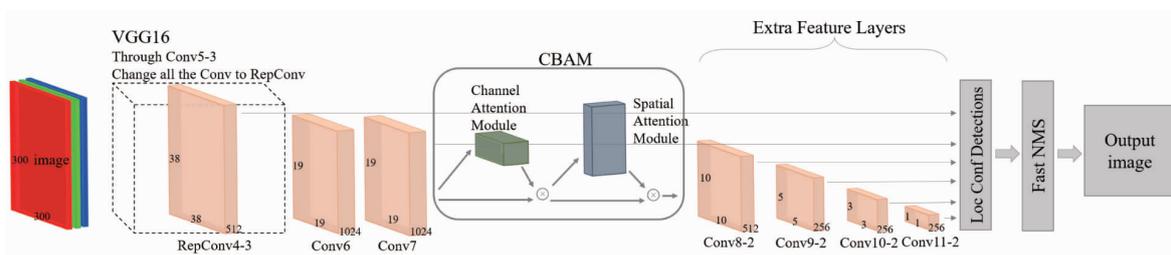


图 2 Rep-SSD 网络结构

表1 Rep-SSD 网络结构参数

网络层	输入	输出	是否为特征提取层
RepConv1	[3, 300, 300]	[64, 150, 150]	否
RepConv2	[64, 150, 150]	[128, 75, 75]	否
RepConv3	[128, 75, 75]	[256, 38, 38]	否
RepConv4	[256, 38, 38]	[512, 19, 19]	RepConv4-3 用于特征层提取
RepConv5	[512, 19, 19]	[512, 19, 19]	否
Conv6	[512, 19, 19]	[1 024, 19, 19]	否
Conv7	[1 024, 19, 19]	[1 024, 19, 19]	Conv7 用于特征层提取
CBA Module	[1 024, 19, 19]	[1 024, 19, 19]	否
Conv8	[1 024, 19, 19]	[512, 10, 10]	Conv8-2 用于特征层提取
Conv9	[512, 10, 10]	[256, 5, 5]	Conv9-2 用于特征层提取
Conv10	[256, 5, 5]	[256, 3, 3]	Conv10-2 用于特征层提取
Conv11	[256, 3, 3]	[256, 1, 1]	Conv11-2 用于特征层提取

2.1 重参数化卷积

重参数化卷积 RepConv 是在 RepVGG 中提出的^[42].RepVGG 借鉴 ResNet(Deep Residual Network)的思想,将 ResNet 网络中的残差结构应用到 VGG,将 VGG 中的卷积层替换成 RepConv.RepConv 通过重参数化的思想,使网络在训练时采用多分支结构,在推理时采用单分支结构.多分支结构能够增强网络的特征提取能力,提高网络的识别精度,单分支结构能够在推理的时候简化网络,提升网络的速度.

RepConv 模块在标准的 3×3 卷积层的基础上增加 2 个残差分支,其中一个是 1×1 的卷积残差分支,另一个是直连(Identity)残差分支.RepConv 模块比标准的 3×3 卷积层多 2 条分支,这使得网络在训练时具有更大的感受野,能够更好地提取输入数据的有用特征.在推理过程中,RepConv 模块使用重参数化将 1×1 的卷积残差分支和 Identity 残差分支与标准的 3×3 卷积结合起来,RepConv 模块变成单分支结构,能够在一定程度上加速网络.RepConv 的模块结构如图 3 所示.

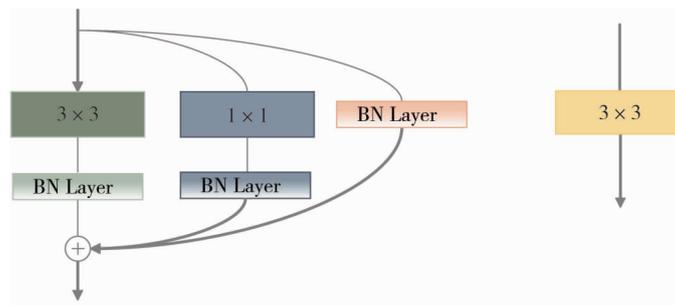


图3 RepConv 模块结构

本文使用 RepConv 模块代替 SSD 目标检测模型骨干网络中的卷积层,目的是让网络有更大的感受野,从而更好地提取浅层特征信息,增强 SSD 目标检测模型中 Conv4-3 层的语义信息,提升网络的小目标检测能力.RepConv 模块在训练时采用多分支结构提高模型的性能,在推理时转换成单分支结构加快模型的速度,节省计算内存.改进后的 Rep-SSD 模型能够保证网络的实时性和识别的准确性.

2.2 卷积块注意力模块

卷积块注意力模块 CBAM 结合通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM),在通道维度和空间维度 2 个维度上分别进行运算,能够使网络同时关注这 2 个维度的信息,通过加权调整信息,实现强调重要信息并抑制不必要信息的效果^[43].

通过 CBAM 注意力机制,网络可以得到由特征图生成的一维通道特征图和二维空间特征图,通道特征图由 CAM 模块生成,空间特征图由 SAM 模块生成.CAM 模块负责提取特征图中有用的信息,并通过最

大池化和平均池化进行提取特征,然后,利用多层感知机(MLP)网络共享网络所学的特征,并采用降维系数来减少计算量;最后,将共享后的特征进行相加,再通过激活函数加权后得到通道注意力特征.SAM 模块负责关注特征图中有用信息的位置,输入的特征层分别采用最大池化和平均池化进行特征提取,然后将提取得到的 2 个特征层拼接起来,通过卷积操作得到最终的空间注意力特征.CBAM 的具体结构如图 4 所示.

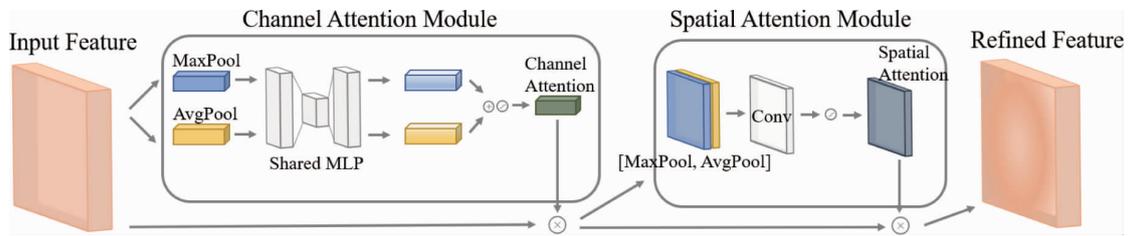


图 4 CBAM 的结构

2.3 算法流程

本文采用 Rep-SSD 模型对交通标志牌进行识别,以验证所提模型的有效性.程序流程图如图 5 所示,具体算法流程如下:

输入:交通标志训练样本数据集(包含数据标签、真实框)、交通标志测试样本数据集和交通标志验证样本数据集.

输出:交通标志验证样本检测结果与检测精度.

- 1) 预处理交通标志数据集并将数据集分成训练集、验证集和测试集.
- 2) 构建训练模型.

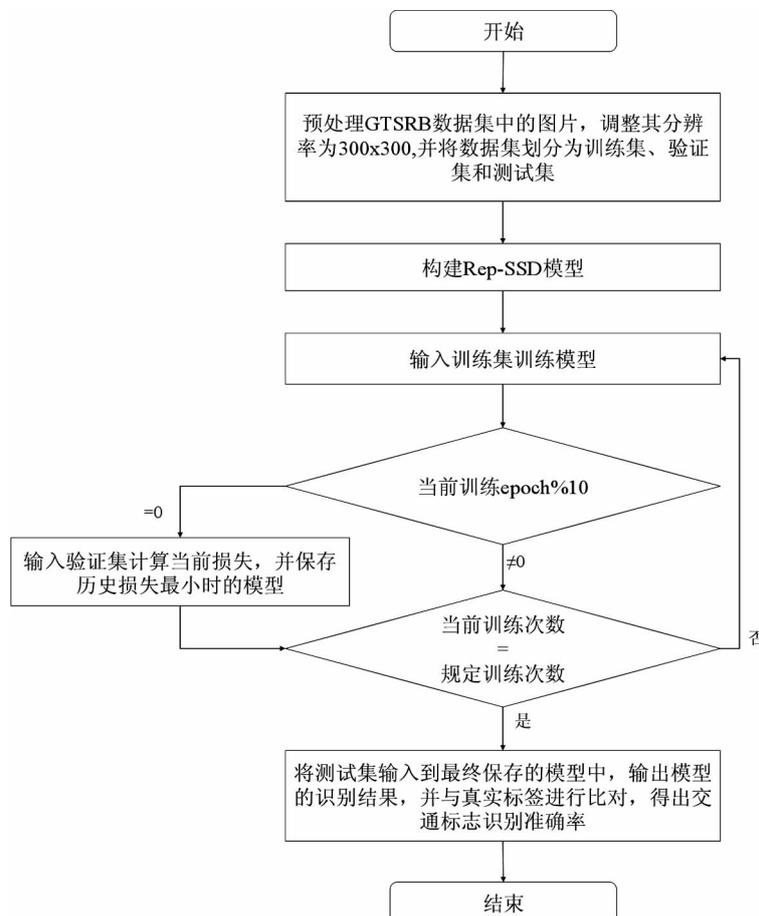


图 5 算法流程

3) 训练模型.

(1) 初始化模型参数.

(2) 输入训练数据至模型,开始训练,重复以下步骤 n 个 epoch: 利用卷积层提取输入图片特征,生成特征图;根据网络设计选择其中 6 层的特征图,在特征图上的每个点生成先验框;计算先验框与真实框的交并比,计算定位损失和分类损失,利用损失函数 L 计算整体训练损失,损失函数 L 为 $L(x, c, l, g) = \frac{1}{N}(L_{\text{conf}}(x, c) + \alpha L_{\text{loc}}(x, l, g))$ (式中: N 为匹配到真实框的先验框数量; L_{conf} 为模型的分​​类损失; L_{loc} 为模型的定位损失; α 为用于调整分类损失和定位损失之间的比例关系)^[22];反向传播整体训练损失,让网络根据整体训练损失更新模型参数.

(3) 得到完成训练的模型.

4) 利用完成训练的模型对测试集图片进行识别.

5) 输出识别结果,即输出交通标志识别准确率.

3 试验与结果分析

3.1 试验数据集

为验证 Rep-SSD 模型的有效性,选用德国交通标志识别数据集 GTSRB^[44],共有 39 208 张照片,43 个类别.数据集按照 80% 和 20% 的比例分割成训练验证集和测试集,其中将训练验证集中的 75% 作为训练集,剩下 25% 作为验证集.

3.2 试验环境

本文试验环境:采用 Intel I9-12900KF 作为 CPU,一块 NVIDIA GeForce RTX 3080Ti 作为 GPU,内存大小为 32 G,操作系统为 Windows 10,实验平台为 PyTorch1.11.0,CUDA 版本为 11.3.

试验参数设置:所使用的 SSD 模型和 Rep-SSD 模型均不使用预训练权重,总训练 epoch 为 100,训练批次大小为 32,训练初始学习率为 0.001,衰减率为 0.000 5,采用 SGD 优化算法,优化算法动量为 0.9,优化算法的 Gamma 系数为 0.1.

3.3 评价指标

采用平均精度(Average Precision, AP)作为模型结果的对比评价指标,分别计算真实框与预测框的重叠比例,计算重叠比例为 0.50~0.95 所对应的 AP 总值并取平均.AP 数值的计算依据是 PR 曲线相交的面积.PR 曲线是指在不同置信度下,由精确度 P (precision) 和召回率 R (recall) 的点所构成的曲线.精确度 P 和召回率 R 的计算公式如下:

$$P = \frac{T_p}{T_p + F_p};$$

$$R = \frac{T_p}{T_p + F_N}.$$

式中: T_p 为被模型预测为正类的正样本; F_p 为被模型预测为正类的负样本; F_N 为被模型预测为负类的正样本.

对于模型的推理速度,本文采用每秒传输帧数(Frames Per Second, FPS)作为模型结果的评价指标,对比不同网络每秒推理照片的数量.

3.4 数据增强

在训练模型时,为了使网络的鲁棒性更强,泛化性能更好和减少过拟合,本文使用图像数据增强技术处理训练时读取的图片.由于数据集所提供的图片尺寸不一,为了保证模型在训练过程中能够提取更多的特征,首先对输入图片进行随机缩放,然后检查缩放后的图片是否满足网络的输入尺寸要求.如果缩放后的图片尺寸超过网络输入尺寸要求,则按照网络输入尺寸进行随机裁剪,然后再进行色域变换.如果缩放后的图片尺寸不满足输入尺寸要求,则进行填充灰色条纹直至满足输入要求,然后再进行色域变换.数

据增强效果如图 6 和图 7 所示.



图 6 图像数据增强示例 1



图 7 图像数据增强示例 2

3.5 试验结果

选定 Faster R-CNN, YOLOv3, YOLOv4, YOLOv4-Tiny 以及 SSD 模型在 GTSRB 数据集上进行训练,按照 3.2 节中的训练参数进行设置,得到对应模型训练后的模型参数文件,利用参数文件对数据集的测试集进行识别.相应模型的结果如表 2 所示.SSD 模型和 Rep-SSD 模型的 AP 值与 mAP (Mean Average Precision) 值结果分别如图 8 和图 9 所示.

表 2 本文算法与其他模型推理准确率和推理速度对比

模型	AP/%	AP _{small} /%	AP _{large} /%	FPS
Faster R-CNN ^[29]	32.4	32.9	22.6	26
YOLOv3 ^[18]	69.2	61.5	81.0	129
YOLOv4 ^[19]	74.8	70.1	86.7	97
YOLOv4-Tiny ^[45]	60.6	62.2	59.7	237
SSD ^[22]	81.0	77.2	89.9	112
Rep-SSD(本文算法)	84.7	81.0	94.2	110

注:AP_{small}为针对检测目标像素面积小于 32×32 的 AP 值;AP_{large}为针对检测目标像素面积大于 96×96 的 AP 值.

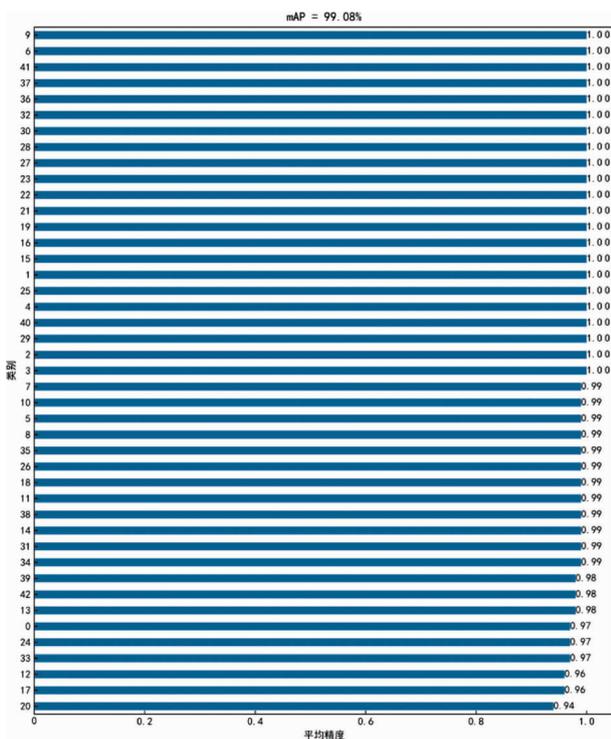


图 8 SSD 模型的 AP 值与 mAP 值

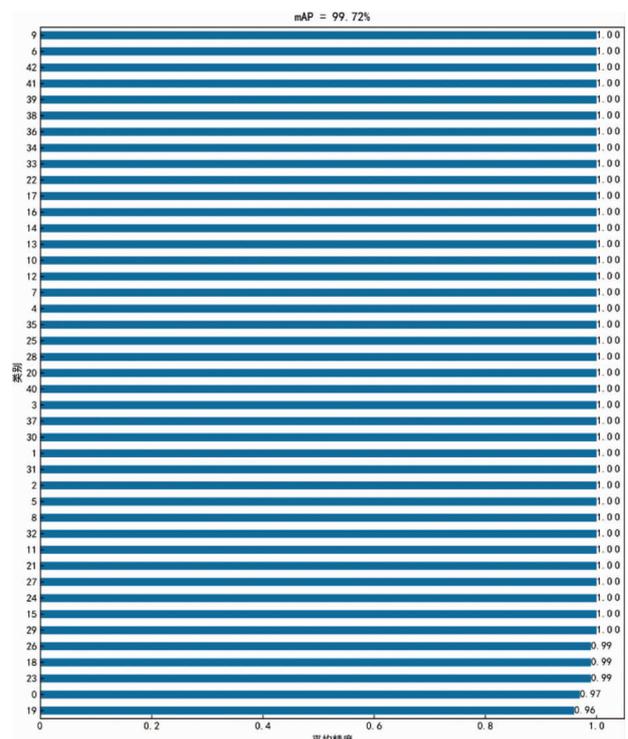


图 9 Rep-SSD 模型的 AP 值与 mAP 值

由表 2 可知:Rep-SSD 的检测精度为 84.7%,检测速度 FPS 为 110 帧每秒,与 SSD 模型相比,AP 值从

81.0%提升至84.7%,提升3.7个百分点,检测速度仅下降2帧每秒,与SSD模型仍处于一个检测速度等级,满足实时性要求的同时提升了模型的检测能力,对小目标的检测效果更好。Rep-SSD的检测效果均比Faster R-CNN, YOLOv3, YOLOv4以及YOLOv4-Tiny好,虽然检测速度不如YOLOv3与YOLOv4-Tiny,但是在精度上有明显提升,与YOLOv3相比,AP值从69.2%提升至84.7%,与YOLOv4-Tiny相比,AP值从60.6%提升至84.7%,分别提升15.5个百分点和24.1个百分点。由图8和图9可知:Rep-SSD模型的mAP值比SSD模型高,且对于不同类别的识别效果都有一定的提升。

图10为Rep-SSD模型和SSD模型检测同一张图片时的结果。由图10可知:在SSD模型识别错误时,Rep-SSD模型能够正确识别,且识别分数达到0.847;在Rep-SSD模型和SSD模型同时识别正确时,Rep-SSD模型的识别分数比SSD模型高。




图10 模型识别结果对比

综上所述,与SSD模型和其他经典模型进行对比时,Rep-SSD模型具有更好的鲁棒性,检测精度更高,在针对小目标识别的时候,能够有更高的概率识别出目标。同时,Rep-SSD模型的检测速度与SSD模型属于同一级别,因此,能够进行实时检测。

3.6 消融实验

本文的消融实验以SSD模型为基准,验证不同模块的改进对模型识别效果的影响。训练参数如3.2节所述,不加载预训练权重。在SSD模型的基础上,依次加入CBAM注意力机制和RepConv模块,同时对RepConv模块进行拆分(分为加入多分支结构和重参数化模型2个部分),以验证不同改进分支对模型的检测精度和检测速度的影响。试验结果如表3所示。

表3 消融实验结果

试验	CBAM 注意力机制	多分支结构	重参数化模型	AP/%	FPS
试验1	-	-	-	81.0	112
试验2	√	-	-	82.2	111
试验3	-	√	-	83.4	87
试验4	-	√	√	83.4	106
试验5	√	√	-	84.7	82
试验6	√	√	√	84.7	110

注:-为不使用该改进策略;√为使用该改进策略。

由表3可知:引入CBAM注意力机制后,模型的AP值从81.0%提升至82.2%,提升1.2个百分点,FPS仅降低1帧每秒;单独加入RepConv模块后,模型的AP值从81.0%提升至83.4%,提升2.4个百分点,重参数化简化前的模型FPS为87帧每秒,简化后提升至106帧每秒;当CBAM注意力机制和RepConv模块共同加入后,检测效果得到显著提升,相比SSD模型,AP值从81.0%提升至84.7%,提升3.7个百分点,检测速度也能够与SSD模型保持在同一水平。

4 结论

1) Rep-SSD 模型可以提升 SSD 模型的小目标检测能力,相比当前主流的单阶段和两阶段目标检测网络,该模型在检测精度与检测速度方面都有一定的优势,具有较好的实时性和准确性,能够应用在自动驾驶领域中。

2) 引入 RepConv 模块可增大模型骨干网络的感受野,提升模型的特征提取能力,使模型在训练过程中能够学习到更多的特征信息。加入 CBAM 注意力机制可以提升网络对目标区域的关注度和有用信息的提取。在德国交通标志牌 GTSRB 数据集上进行试验,结果表明,Rep-SSD 的检测精度可达 84.7%, AP_{small} 可达 81.0%, AP_{large} 可达 94.2%,FPS 可达 110 帧每秒。

3) 大量的对比试验与消融实验进一步验证改进算法的优越性与可行性,体现该算法在自动驾驶领域中的实用价值。

参考文献:

- [1] 彭育辉,江铭,马中原,等.汽车自动驾驶关键技术研究进展[J].福州大学学报(自然科学版),2021,49(5):691-703.
- [2] 肖雨晴,杨慧敏.目标检测算法在交通场景中应用综述[J].计算机工程与应用,2021,57(6):30-41.
- [3] XUE B, YI W J, JING F, et al. Complex ISAR target recognition using deep adaptive learning[J]. Engineering Applications of Artificial Intelligence, 2021, 97: 104025.
- [4] XUE B, TONG N N. Real-world ISAR object recognition using deep multimodal relation learning[J]. IEEE Transactions on Cybernetics, 2020, 50(10): 4256-4267.
- [5] XUE B, HE Y, JING F, et al. Robot target recognition using deep federated learning[J]. International Journal of Intelligent Systems, 2021, 36(12): 7754-7769.
- [6] XUE B, TONG N N. DIOD: fast and efficient weakly semi-supervised deep complex ISAR object detection[J]. IEEE Transactions on Cybernetics, 2019, 49(11): 3991-4003.
- [7] 伍晓晖,田启川.交通标志识别方法综述[J].计算机工程与应用,2020,56(10):20-26.
- [8] GAVRILA D M. Traffic sign recognition revisited[C]//FÖRSTNER W, BUHMANN JM, FABER A, et al. Mustererkennung 1999. Berlin, Heidelberg: Springer, 1999: 86-93.
- [9] PICCIOLI G, DE MICHELI E, PARODI P, et al. Robust method for road sign detection and recognition[J]. Image and Vision Computing, 1996, 14(3): 209-223.
- [10] 许少秋.户外交通标志检测和形状识别[J].中国图象图形学报,2009,14(4):707-711.
- [11] 朱双东,刘兰兰,陆晓峰.一种用于道路交通标志识别的颜色-几何模型[J].仪器仪表学报,2007,28(5):954-958.
- [12] CREUSEN I M, HAZELHOFF L, DE WITH P H N. Color transformation for improved traffic sign detection[C]//2012 19th IEEE International Conference on Image Processing. IEEE, 2012: 461-464.
- [13] MADANI A, YUSOF R. Traffic sign recognition based on color, shape, and pictogram classification using support vector machines[J]. Neural Computing and Applications, 2018, 30(9): 2807-2817.
- [14] 赵宏伟,陈霄,石景海,等.综合颜色和形状特征的交通标志图像检索算法[J].吉林大学学报(工学版),2013,43(增刊1):128-132.
- [15] 赵永强,饶元,董世鹏,等.深度学习目标检测方法综述[J].中国图象图形学报,2020,25(4):629-654.
- [16] 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). IEEE, 2016: 779-788.
- [17] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 6517-6525.
- [18] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. 2018: arXiv: 1804.02767. <http://arxiv.org/abs/1804.02767>.
- [19] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. 2020: arXiv: 2004.10934. <http://arxiv.org/abs/2004.10934>.

- [20] LI C Y, LI L L, JIANG H L, et al. YOLOv6: a single-stage object detection framework for industrial applications[EB/OL]. 2022; arXiv: 2209.02976. <http://arxiv.org/abs/2209.02976>.
- [21] 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[EB/OL]. 2022; arXiv: 2207.02696. <http://arxiv.org/abs/2207.02696>.
- [22] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [23] DEWI C, CHEN R C, JIANG X Y, et al. Deep convolutional neural network for enhancing traffic sign recognition developed on Yolo V4[J]. Multimedia Tools and Applications, 2022, 81(26): 37821-37845.
- [24] 潘卫国,刘博,陈英昊,等.基于YOLOv3的交通标志牌检测识别[J].传感器与微系统,2019,38(11):147-150.
- [25] 江金洪,鲍胜利,史文旭,等.基于YOLOv3算法改进的交通标志识别算法[J].计算机应用,2020,40(8):2472-2478.
- [26] 郭继峰,孙文博,庞志奇,等.一种改进YOLOv4的交通标志识别算法[J].小型微型计算机系统,2022,43(7): 1471-1476.
- [27] 李志刚,张娜.一种轻量型YOLOv5交通标志识别方法[J].电讯技术,2022,62(9):1201-1206.
- [28] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. ACM, 2014: 580-587.
- [29] 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.
- [30] 邓天民,方芳,周臻浩.基于改进空间金字塔池化卷积神经网络的交通标志识别[J].计算机应用,2020,40(10): 2872-2880.
- [31] SERMANET P, LECUN Y. Traffic sign recognition with multi-scale Convolutional Networks[C]//The 2011 International Joint Conference on Neural Networks. IEEE, 2011: 2809-2813.
- [32] CHENG P, LIU W, ZHANG Y F, et al. LOCO: local context based faster R-CNN for small traffic sign detection[C]//International Conference on Multimedia Modeling. Cham: Springer, 2018: 329-341.
- [33] 徐国整,周越,董斌,等.基于改进CascadeR-CNN的交通标志牌识别[J].传感器与微系统,2021,40(5):142-145,153.
- [34] 王海,王宽,蔡英凤,等.基于改进级联卷积神经网络的交通标志识别[J].汽车工程,2020,42(9):1256-1262,1269.
- [35] 黄志强,李军.基于空间通道注意力机制与多尺度融合的交通标志识别研究[J].南京邮电大学学报(自然科学版), 2022,42(2):93-102.
- [36] 尉天成,陈小锋,殷元亮.基于多尺度卷积神经网络的道路交通标志识别方法研究[J].西北工业大学学报,2021,39(4):891-900.
- [37] 林轶,陈琳,王国鹏,等.改进的YOLOv3交通标志识别算法[J].科学技术与工程,2022,22(27):12030-12037.
- [38] 田智慧,孙盐盐,魏海涛.基于SSD模型的交通标志检测算法[J].计算机应用与软件,2021,38(12):201-206.
- [39] 崔静雯,马杰,张宇.基于多尺度联合权重分配的目标检测算法[J].计算机工程与应用,2022,58(17):101-110.
- [40] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. 2014; arXiv: 1409.1556. <http://arxiv.org/abs/1409.1556>.
- [41] 陈飞,刘云鹏,李思远.复杂环境下的交通标志检测与识别方法综述[J].计算机工程与应用,2021,57(16):65-73.
- [42] DING X H, ZHANG X Y, MA N N, et al. RepVGG: making VGG-style ConvNets great again[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021:13728-13737.
- [43] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [44] STALLKAMP J, SCHLIPSING M, SALMEN J, et al. Man vs. computer: benchmarking machine learning algorithms for traffic sign recognition[J]. Neural Networks, 2012, 32: 323-332.
- [45] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Scaled-YOLOv4: scaling cross stage partial network[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021: 13024-13033.