

应用于交通标志的单步多目标检测方法研究

杜云龙, 强俊, 王洪铭, 肖光磊, 孙宇

安徽工程大学 计算机与信息学院, 安徽 芜湖 241000

摘要:目的 针对自然场景下交通标志检测存在的小目标精度低和目标特征信息不足等问题, 提出一种使用残差网络(Residual Network, ResNet)和注意力机制(Attention Mechanism)的单步多目标检测算法 SSD (Single Shot MultiBox Detector), 经过残差网络和注意力机制提取的特征向量输送到一个轻量、高效的特征融合模块中, 最后将输出的 feature map 送到检测器中进行检测, 从而提升交通标志检测的正确率。方法 首先, 利用残差模块将特征进行 1×1 降维再 3×3 升维, 然后将恒等映射和残差部分生成的特征图进行逐像素相加; 其次, 将 CBAM (Convolutional Block Attention Module) 引入到残差模块 Conv4_x 输出的特征图上, 然后与残差模块 Conv2_x, Conv3_x 输出的特征图一起输入到高效的特征融合模块中进行特征融合, 最后将融合后的特征图送入模型中检测以实现交通标志的识别。结果 通过仿真实验验证, 改进后的单步多目标检测算法 SSD 在中国交通标志检测数据集上进行检测的平均精度为 90.55%, 能够有效地提取小目标特征的信息。相较于主流算法 CenterNet、YOLOv3、YOLOv4、Faster R-CNN、SSD 分别提高了 2.57%、3.4%、2.79%、3.8%、4.93%。结论 优化后的目标检测方法相较于其他检测方法提取到了更多的特征信息, 达到了更高的检测精度, 在交通标志检测中具有良好的实用性和有效性。

关键词: 交通标志检测; SSD 算法; 残差网络; 特征融合; CBAM

中图分类号: O643 文献标识码: A doi: 10.16055/j.issn.1672-058X.2025.0001.009

Research on Single Shot Multibox Detector Applied to Traffic Signs

DU Yunlong, QIANG Jun, WANG Hongming, XIAO Guanglei, SUN Yu

School of Computer and Information, Anhui Polytechnic University, Anhui Wuhu 241000, China

Abstract: Objective In response to the issues of low accuracy in detecting small objects and insufficient target feature information in natural scenes for traffic sign detection, a single shot multibox detector (SSD) algorithm using residual network (ResNet) and attention mechanism was proposed. The feature vectors extracted by residual networks and attention mechanisms were fed into a lightweight and efficient feature fusion module. Finally, the output feature map was sent to the detector for detection, thereby enhancing the accuracy of traffic sign detection. **Methods** Firstly, the features were dimensionally reduced by 1×1 and then increased by 3×3 using residual modules, and then the feature maps generated by the constant mapping and residual parts were summed pixel by pixel. Secondly, the convolutional block attention module (CBAM) was introduced to the feature map output by Conv4_x of the residual module. Then, the feature map output by the residual module Conv4_x and the feature maps output by the residual modules Conv2_x and Conv3_x were fed into the efficient feature fusion module for feature fusion. Finally, the fused feature map was sent to the model for detection to realize the recognition of traffic signs. **Results** Through simulation experiments, the improved SSD algorithm achieved an

收稿日期: 2023-06-19 修回日期: 2023-08-20 文章编号: 1672-058X(2025)01-0064-08

基金项目: 安徽省高校优秀拔尖人才培养资助项目(GXYQZD2021123); 国家级大学生创新创业计划项目(S202110363098)。

作者简介: 杜云龙(1999—), 男, 安徽阜阳人, 硕士, 从事目标检测研究。

通讯作者: 强俊(1981—), 女, 安徽芜湖人, 硕士, 副教授, 从事机器视觉研究。Email: chiang_j@aphu.edu.cn.

引用格式: 杜云龙, 强俊, 王洪铭, 等. 应用于交通标志的单步多目标检测方法研究[J]. 重庆工商大学学报(自然科学版), 2025, 42(1): 64-71.

DU Yunlong, QIANG Jun, WANG Hongming, et al. Research on single shot multibox detector applied to traffic signs[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(1): 64-71.

average precision of 90.55% for detection on the Chinese traffic sign detection dataset, effectively extracting feature information from small objects. Compared with mainstream algorithms including CenterNet, YOLOv3, YOLOv4, Faster R-CNN, and SSD, the improved SSD algorithm improved the accuracy by 2.57%, 3.4%, 2.79%, 3.8%, and 4.93%, respectively. **Conclusion** The optimized object detection method extracts more feature information and achieves higher detection accuracy compared with other detection methods, demonstrating good practicality and effectiveness in traffic sign detection.

Keywords: traffic sign detection; SSD algorithm; residual network; feature fusion; CBAM

1 引言

随着智能交通的快速发展,交通标志识别在促进车辆通行和交通安全等领域扮演着重要的角色。在实际场景中,交通标志存在着目标较小、背景复杂以及可能被遮挡等原因,使交通标志的检测面临着很多困难。

针对上诉问题,近年来研究人员提出了许多不同的检测方法,主要有两类:传统检测方法和基于深度学习的检测方法。传统方法主要分为基于颜色空间^[1]、基于形状特征^[2]。然而,这两类算法容易受到如遮挡等各种不利因素的影响。在这些方法的基础上,研究人员提出了基于深度学习的检测方法,目前主要分为两阶段算法和单阶段算法。传统方法的代表有张毅^[3]提出的改进 Faster R-CNN 和徐国整^[4]提出的改进 Cascade R-CNN 方法,这类算法通过引入区域建议网络(RPN)来进一步提高检测性能,RPN 作为一个全卷积网络,可以同时预测每个位置的目标边界和目标得分,并于检测网络共享全图卷积特征。经过端到端训练,RPN 可以生成高质量的区域建议。但它的缺点在于网络过于复杂,检测速度慢;后者的典型代表有 Redmon J 提出的 YOLO^[5-8] 系列和 Liu W 提出的 SSD^[9] 方法,此类算法消除了区域建议阶段,直接将检测层添加到主干网络中进行分类和回归,大大提高了检测网络的检测速度。Zhou^[10] 等设计了一种具有并行融合注意模块的注意力网络,有效地解决了在各种气候、光照以及遮挡等不同环境条件下,交通标志检测精度不高的问题,然而模型参数较多,训练时模型振荡幅度较大、检测速度慢;李世裴等^[11] 通过 SSD 定位目标像素坐标进而提高工业机器人抓取的能力,但并没有对 SSD 算法进行优化。张学峰等^[12] 提出了 YOLO-CDF 算法,提高了对安全帽检测的准确性并针对小目标提高了识别率,但网络模型较大,在检测速度上还有提升空间。

综上,两阶段算法度一般高于单阶段算法,但两阶段算法的计算速率较慢,无法满足实际应用中实时性的需求。而单阶段算法能够同时保证了精度和处理速度,因此其应用范围更加广泛。然而,由于交通标志通常为小目标物体,所以,上诉检测模型均无法

满足实际需求。

基于此,提出了改进思路:首先,设计残差网络 ResNet50 取代原来的 VGG-16 主干网络,提升网络特征提取能力,同时残差网络可以解决网络过深可能出现的梯度消失和梯度爆炸问题;其次,引入注意力机制,使网络更专注于图像中更重要的部分,有助于提高模型对小目标物体的检测精度;最后,使用一个轻量级的结构来实现融合高低层 Feature map 特征的目的,在降低参数数量的同时提高检测速度和精度。

2 SSD 网络结构

SSD 是一种非常经典的单阶段目标检测模型。该网络以 VGG16 为主干网络。SSD 中只用到了 VGG16 的前 5 层卷积,在特征提取后添加多个卷积层取代后面的全连接层,如图 1 所示。经过 Softmax 分类和位置回归后,输出多个预测结果。SSD 采用了多尺度映射,并为每个特征图设计了不同数量、尺度和宽高比的先验框。尺度的生成方法如式(1)所示:

$$s_k = s_{\min} + \frac{(s_{\max} - s_{\min})}{m-1}(k-1), k \in [1, m] \quad (1)$$

其中, s_k 表示第 k 个特征图中先验框的尺度, m 是使用特征图的数量,而 s_{\max} 和 s_{\min} 表示设置比例的最大值和最小值。

先验框的宽高比例通常取 $\{1, 2, 3, 1/2, 1/3\}$ 。在确定尺度和宽高比后,先验框的大小可由式(2)和式(3)得出:

$$w_k^a = s_k \sqrt{a_r} \quad (2)$$

$$h_k^a = s_k / \sqrt{a_r} \quad (3)$$

其中, w_k^a 和 h_k^a 分别为先验框的宽和高。对于宽高比例为 1 的先验框,会另增一个尺度,其计算方法如式(4)所示:

$$s'_k = \sqrt{s_k s_{k+1}} \quad (4)$$

由 SSD 网络的构造可以看出,SSD 算法利用了回归的思想,减少了神经网络计算量,提高了算法检测性能和速度,但 SSD 在进行小目标检测的浅层特征图上,由于语义信息的缺乏,其在小目标检测上的表现并不理想。网络模型如图 1 所示。

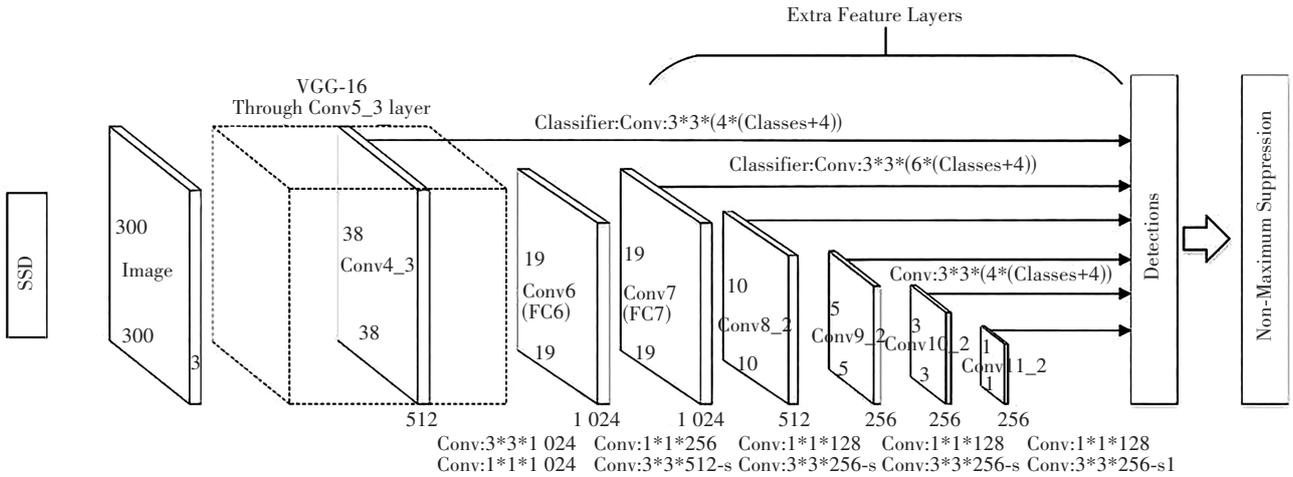


图 1 SSD 网络结构图

Fig. 1 Architecture of SSD network

3 模型改进

3.1 残差网络 ResNet50

ResNet50 模型是由 50 个卷积层组成,其中包括了多个残差块。这些残差块通过跨层连接的方式使得信息可以更加轻松地在网络中传递,从而避免了梯度消失的问题。相比于原 SSD 使用的 VGG16 模型,ResNet50 可以训练更深的网络,提高网络的精度和性能。残差网络如图 2 所示。

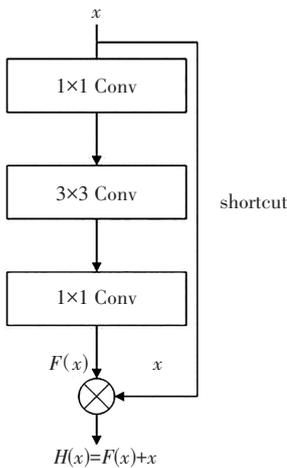


图 2 残差网络

Fig. 2 Residual network

在残差结构中,左分支将输入特征 x 通过 1×1 卷积降维,然后使用 3×3 卷积提取特征,再通过 1×1 卷积进行升维,生成残差映射结果 $F(x)$ 。相较于 VGG16,ResNet50 网络使用大量的 1×1 卷积来减少模型的数量和计算量。在残差结构中,右分支进行恒等映射 x ,并与残差映射 $F(x)$ 逐元素相加,得到输出结果 $H(x)$ 。因此,网络学习到的残差特征可以表示为

$$F(x) = H(x) - x \quad (5)$$

在极端情况下,当残差结构的映射结果 $F(x)$ 为 0

时,残差结构仅执行恒等映射,网络仍然具有之前迭代后的学习能力。因此,即使模型深度增加,网络的学习能力也不会下降。实际上, $F(x)$ 很难永远为 0,因为残差结构能够通过其残差分支学习新的特征,进而增强网络的学习能力。因此,残差结构可以有效地解决网络深度增加引起的网络退化问题。此外,由于残差结构中的每个卷积层后都会进行批量归一化操作 (Batch Normalization, BN) 和 ReLU 激活函数,可以加快网络的收敛速度。因此,还能缓解由于梯度消失或梯度爆炸而引起的无法正常训练的问题。

3.2 轻量高效的特征融合模块

特征融合是目标检测中的关键手段之一。低层特征通常具有更高的分辨率和更多的位置细节信息,但由于经过的卷积层数较少,因此语义信息较低。而高层特征虽然分辨率较低,但却具有更丰富的语义信息。因此,怎样将高、低层特征融合是提高目标检测性能的关键。

许多方法通过融合不同尺度的特征来提升检测模型的性能,如图 3 所示, F 表示特征图, P 表示预测模块。图 3(a)展示了原始的 SSD 预测层结构,通过在多个尺度的特征层上直接进行预测。

然而,各个层之间完全没有联系,因此浅层的高分辨率特征由于语义信息不足导致不能有效检测小目标。Lin 等^[13]提出了特征金字塔网络,如图 3(b)。通过建立一条自顶向下的路径,从顶层特征开始逐层上采样,并将它们与特征提取网络中的特征图进行逐像素相加融合,这就实现了将浅层特征和深层特征进行融合,但这种方式在每一次上采样之后都进行逐像素相加操作,带来了大量的冗余计算。

引用一种高效轻量的特征融合模块,如图 3(c)。将特征提取网络的最后 3 个模块的输出特征 F_2 、 F_3 和

F_4 进行 Concat 特征融合,再连接一系列的额外特征提取层 F_5 、 F_6 、 F_7 和 F_8 ,最终在不同尺度不同大小的特征上进行预测。相较于原 SSD,结构加入了特征融合模块可以增强浅层特征的语义信息和小目标的检测能力。相较于 FPN,结构的特征融合模块仅在特征提取网络末尾作一次 Concat 特征融合,大大降低了模型的数量和计算量,并防止了特征冗余造成的模型性能下降。

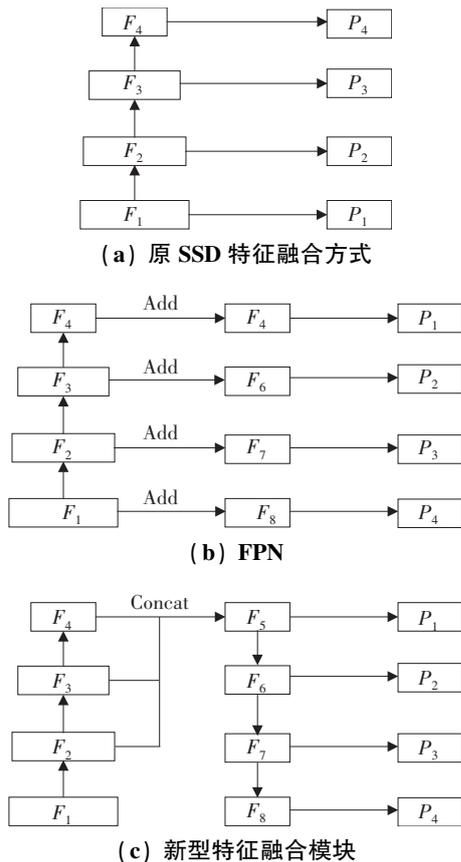


图 3 3 种经典的特征融合方式

Fig. 3 Three classic feature fusion methods

3.3 选择性注意力模块

深度学习中,注意力机制可有效提升网络特征提取的性能。Hu 等^[14]在 2018 年设计了通道注意力的有效机制,提出了 SE-NET(Squeeze-and-Excitation Net-works),建立起了特征图中的空间相关性。ECA-Net(Efficient Channel Attention Networks)将 SE-Net 中的 MLP 模块替换成一维卷积的形式,有效地减少了参数计算量。之后,Woo 等^[15]提出了 CBAM 机制,其在 SE-Net 或 ECA-Net 的通道注意力机制中增加了空间注意力机制。CBAM 的通道注意力机制用于对每个通道进行加权,以强调对于目标分类任务有用的特征。空间注意力机制用于对空间位置进行加权,以保留有用的特征区域,而忽略不重要的区域。相比 SE-Net 和 ECA-Net,CBAM 机制将两者结合帮助目标检测网络再复杂环境中更高效地检测目标,如图 4 所示。

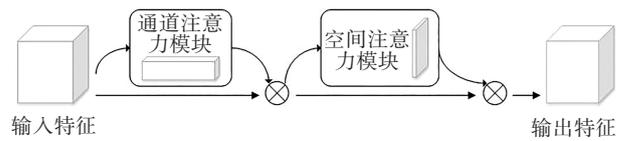


图 4 CBAM 注意力机制

Fig. 4 CBAM attention mechanism

将 CBAM 注意力机制加入 ResNet50 的最后一个卷积层的输出上,用来捕获全局上下文信息,并且能够进一步增强模型对目标的特征提取的能力。

3.4 改进后的检测模型

提出的改进 SSD 模型如图 5 所示。输入图片尺寸为 300×300 ,并对 ResNet50 网络做出部分调整,删除了最后的 Conv5、平均池化层、全连接层及 Softmax 层等结构,以适应作为 SSD 算法的特征提取。

为了增加底层高分辨率特征图的语义信息,在 ResNet 的最后 3 个模块 Conv2_x、Conv3_x、Conv4_x 的输出特征图之后连接了一个高效轻量的特征融合模块:

(1) 将 Conv2_x 模块输出的 $256 \times 75 \times 75$ 大小的特征图通过一个 1×1 卷积降维到 $128 \times 75 \times 75$ 大小。

(2) 将 Conv3_x 模块输出的 $512 \times 38 \times 38$ 大小的特征图先通过一个 1×1 的卷积降维到 $128 \times 38 \times 38$ 大小,再通过一个 2 倍的双线性插值(Bilinear Interpolation)上采样将特征图宽高扩大两倍,得到 $128 \times 75 \times 75$ 大小的特征图。

(3) 将 Conv4_x 模块输出的 $1024 \times 19 \times 19$ 大小的特征图先通过一个 1×1 的卷积降维到 $128 \times 19 \times 19$ 大小,再通过一个 4 倍的双线性插值上采样将特征图宽高扩大 4 倍,得到 $128 \times 75 \times 75$ 大小的特征图。

(4) 将这 3 个大小相同、维度相同的特征图进行逐通道相加,得到融合后 $384 \times 75 \times 75$ 大小的特征图。特征图融合了 3 个尺度的语义信息,可以有效缓解浅层特征的低语义问题。

在传统 SSD 算法中,在特征提取网络 VGG16 之后与特征提取层连接,生成了 6 个预测特征图。类似的,本文在特征融合层后先使用一个 1×1 卷积和一个 BN 层对融合后的特征图进行降维,得到一个 $128 \times 75 \times 75$ 大小的特征图。在依次连接 7 个额外特征提取层,每个额外特征层都是相同的结构。为了和特征提取网络 ResNet50 相对应,抛弃了传统 SSD 模型中的 3×3 卷积和 1×1 卷积相互堆叠的额外特征提取层结构,而是采用了一种类似瓶颈结构的残差块。通过先降维,然后提取特征,再升维,最后进行残差连接的方式,既可以有效地降低参数,又能更好的提取特征。最终生成了 $128 \times 75 \times 75$ 、 $256 \times 38 \times 38$ 、 $512 \times 19 \times 19$ 、 $256 \times 10 \times 10$ 、 $512 \times 5 \times 5$ 、 $256 \times 3 \times 3$ 、 $512 \times 1 \times 1$ 等 7 个不同大小、不同长宽比的预测特征图,再送入检测器中进行交通标志检测。

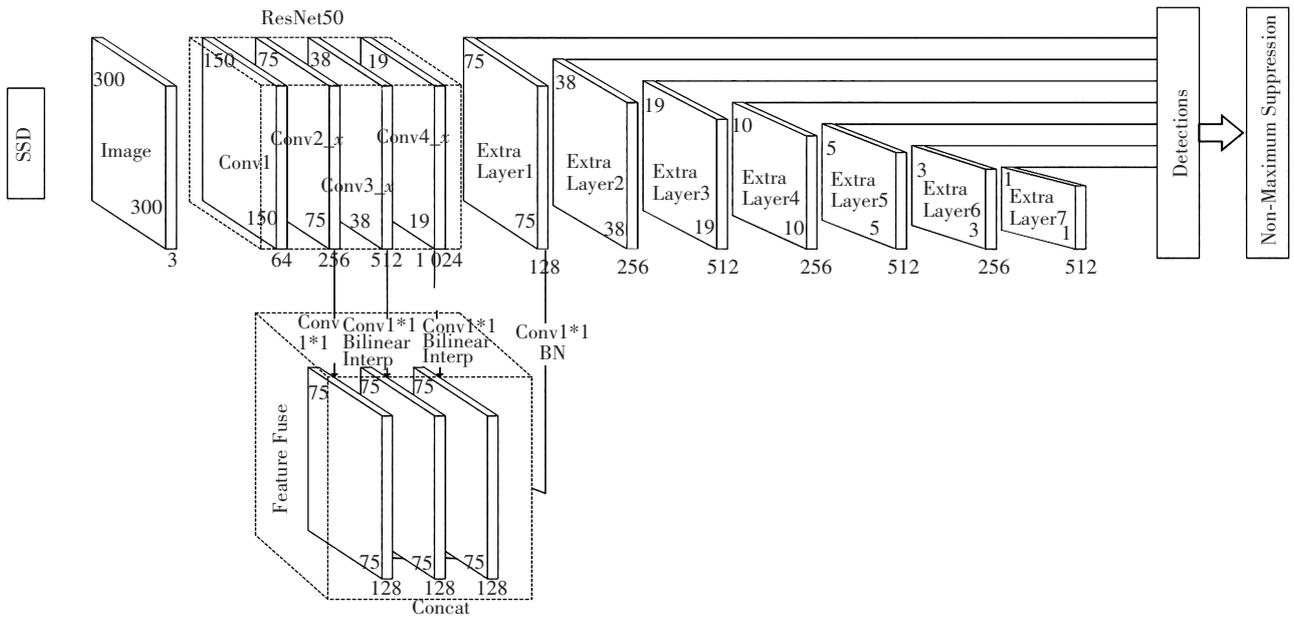


图 5 改进后的网络结构图

Fig. 5 Architecture of improved network

4 仿真实验与结果分析

4.1 实验平台

实验采用了带有 Ubuntu18.04 的 Linux 计算机。硬件环境: Intel(R) Core(TM) i9-10940x CPU @ 3.30 GHz, 64 GRAM; NVIDIA GeForce RTX3080 GPU。软件环境: Python 3.7, PyTorch1.9.0, CUDA 11.0。

4.2 数据集

CCTSDB 是中国交通标志数据基准, 数据包含了 15 734 张真实场景图像。分为 3 个类别: mandatory、prohibitory、warning。

为降低相似图像对实验的干扰, 删去 CCTSDB 中相似图像 1 904 张, 并在其中选取合适的 2 164 张图像进行数据增强操作, 对符合条件的图片进行 GridMask、Solarize_add、Posterize 扩充, 使其具有更多的真实场景中的可能情况。训练集与测试集按照 9 : 1 划分, 对本文改进的算法进行评估。

4.3 实验评价指标

采用检测精度 f_p 、平均精度 f_{AP} 、均值平均精度 f_{mAP} 和每秒可处理的图像数量 FPS 作为评价指标。计算公式为

$$f_p = \frac{T_p}{T_p + F_p} \tag{6}$$

$$f_{AP} = \frac{\sum f_p}{Num(Total_Objects)} \tag{7}$$

$$f_{mAP} = \frac{\sum f_{AP}}{Class_num} \tag{8}$$

式(6)中, T_p 表示被模型预测为正类的正样本数量; F_p

表示被模型预测为正类的负样本数量; 式(8)中, $Class_num$ 为目标类别数。

4.4 实验结果分析与对比

现将本文改进的 SSD 检测算法与其他先进的方法进行比较, 其中包括基于 Anchor-free 的 CenterNet, YOLO 系列的 YOLOv3、YOLOv4, Faster R-CNN 以及原 SSD。实验结果如表 1 所示。

表 1 不同模型性能结果对比

Table 1 Performance comparison of different models

Model	f_{mAP} /%	$f_{AP}/\%$			FPS /帧	Params /M
		Mandatory	Prohibitory	Warning		
CenterNet	87.98	85.95	88.40	89.50	22	32.66
YOLOv3	87.15	87.63	85.63	88.19	67	61.94
YOLOv4	87.76	91.55	85.32	86.41	47	64.36
Faster RCNN	86.75	84.91	86.39	87.29	45	137.09
SSD	85.62	86.44	83.87	86.56	86	26.28
改进 YOLOX ^[16]	88.63	—	—	—	29	27.98
OURS	90.55	90.59	90.29	90.77	35	44.12

可以看出, 改进的 SSD 算法在各个评价指标上表现出良好的结果。CenterNet 的检测精度为 87.98%, 而 FPS 仅为 22, 检测时间较长; YOLO v3 和 YOLO v4 在准确率方面达到了 87.15% 和 87.76%, 检测速度也较快, 但参数量增加较多; Faster RCNN 的检测精度为 86.75%, 参数量却有 137.09 M, 这不利于模型的部署; 原 SSD 虽然参数量小, 检测速度快, 但检测精度仅为 85.62%。文献[16]在提高检测精度后, 检测速度大幅下降, FPS 仅为 29。改进的 SSD 算法与表现较好的文献[16]相对比, 在参数量小幅增加的情况下, mAP 值达

到 90.55%,且 FPS 达到了 35。表明模型有较高的检测速度和检测精度,满足移动端实时检测。各算法的检测效果如图 6、图 7 所示。



(a) CenterNet



(b) YOLOv3



(c) YOLOv4



(d) Faster R-CNN



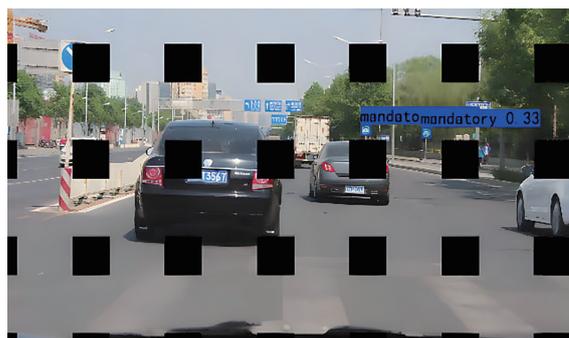
(e) SSD



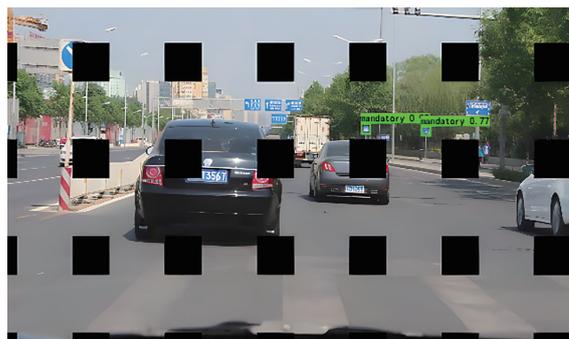
(f) Ours

图 6 不同模型的无遮挡检测效果

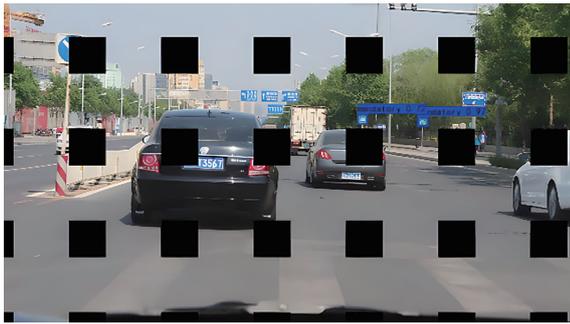
Fig. 6 Detection performance of different models for traffic signs without occlusion



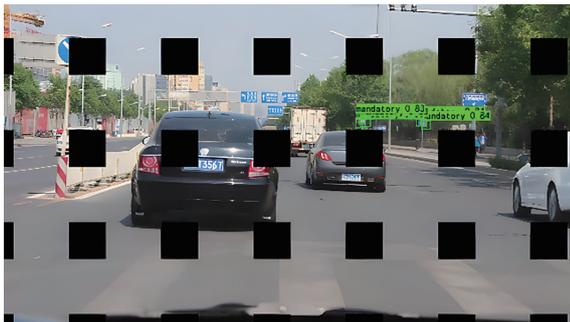
(a) CenterNet



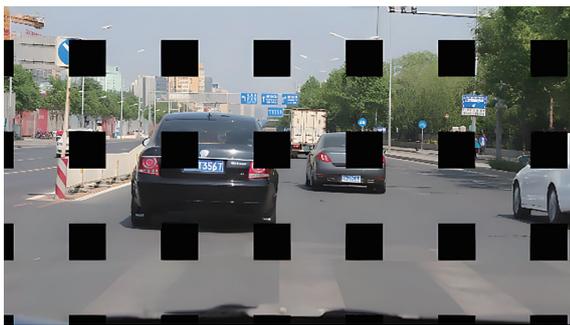
(b) YOLOv3



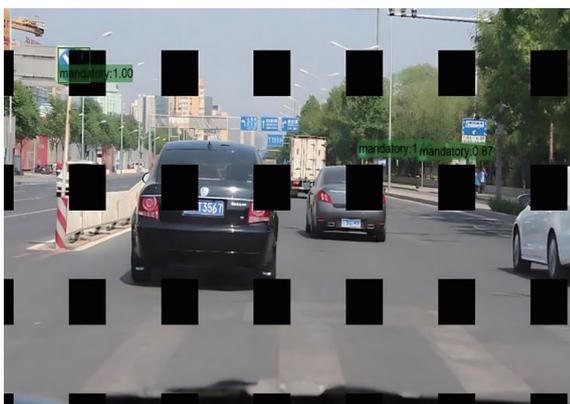
(c) YOLOv4



(d) Faster R-CNN



(e) SSD



(f) OURS

图 7 不同模型的有遮挡检测效果

Fig. 7 Detection performance of different models with occluded traffic signs

从图 6 可以看出,当交通标志在无遮挡情况下时原 SSD 未能识别全部目标,CenterNet 与 YOLOv3 的识别结果的置信度分别为 0.56 和 0.71,低于改进后 SSD

的 0.88。而 YOLOv4 和 Faster R-CNN 在无遮挡情况下与改进后的 SSD 检测效果近似。

从图 7 可以看出,当交通标志存在遮挡情况时除改进后 SSD 算法外均存在错检、漏检情况。

4.5 消融实验

为了验证所提出的改进措施是否有效,设计了一组消融实验,通过组合所提及修改网络、设计特征融合方式、添加 CBAM,来验证对网络的影响。具体实验性能见表 2。

可以看出,通过改进主干网络,参数量小幅增加,mAP 提高了 1.3%,说明 ResNet50 能够更好地提取目标特征。在 ResNet50 网络的基础上添加 CBAM 模块使 mAP 提高了 0.57%,这表明 CBAM 模块使特征提取网络更加关注于重点区域,进一步提高了网络的特征提取能力。此外,通过加入轻量融合模块到 ResNet50 网络中,该模块整合了高层和底层特征,有效改善了对小目标检测的性能,mAP 显著提升至 89.38%。

对比 SSD 和模型 ResNet50 可知,ResNet50 (R)、CBAM (C)、Fusion Feature (F) 对于模型均增加了参数量,但性能都得到了不同程度的提升。RFC-SSD 在应用了全部改进方法后实现了最佳的检测性能,在 mAP 上取得了最优的结果,与基线网络相比,提升了 4.93%,并且满足了检测的实时性。根据消融实验结果可知,改进方案对网络性能的提升是有效的。

表 2 消融实验

Table 2 Ablation experiments

Model	f_{mAP} /%	$f_{AP}/\%$			FPS /帧	Params /M
		Mandatory	Prohibitory	Warning		
SSD	85.62	86.44	83.87	86.56	86	26.28
SSD+R	86.92	88.08	85.65	87.03	72	29.80
SSD+R+C	87.47	89.05	85.80	87.56	68	35.52
SSD+R+F	89.38	89.85	89.07	89.23	63	37.35
SSD+R+F+C	90.55	90.59	90.29	90.77	35	44.12

5 结论

为了解决单步多目标检测算法 SSD 对交通标志小目标检测精度不佳的问题,提出了一种改进 SSD 的交通标志检测算法。方法使用残差网络,提高网络的特征提取能力的同时不会带来由于网络加深造成的网络退化问题。其次,添加 CBAM 选择性注意模块使网络更加关注目标特征信息,减少复杂背景对检测效果的干扰。最后,将残差网络的后 3 个卷积输出的 feature map 进行融合,使其特征图更具多样性。

由实验结果可以得出结论:改进后的 SSD 算法对

于遮挡图像具有更好的鲁棒性。与改进前相比,在有遮挡图像上的检测表现更佳。与原 SSD 模型相比,改进后的 SSD 模型在 3 种交通标志的检测效果中均有提高且平均精度达到 90.55%,比原版 SSD 提高了 4.93%。此外,改进后的 SSD 模型的 mAP 值均超过 CenterNet、YOLOv3、YOLOv4 和 Faster R-CNN。

未来的研究方向,一是进一步提高检测速率,二是考虑在更加复杂的环境中保持较高的检测精度。

参考文献(References):

- [1] 王济民,魏怡,周宇,等. 基于 LeNet-5 卷积神经网络和颜色特征的限速标志识别[J]. 计算机科学, 2021, 48(S2): 345-350.
WANG Ji-min, WEI Yi, ZHOU Yu, et al. Speed limit sign recognition based on LeNet-5 CNN and color feature [J]. Computer Science, 2021, 48(S2): 345-350.
- [2] 苗丹,卢伟,高娇娇,等. 基于聚类与 Hough 变换的交通标志检测方法[J]. 计算机系统应用, 2019, 28(11): 213-217.
MIAO Dan, LU Wei, GAO Jiao-jiao, et al. Traffic sign detection method based on clustering and Hough transform[J]. Computer Systems & Applications, 2019, 28(11): 213-217.
- [3] 张毅,龚致远,韦文闻. 基于改进 Faster R-CNN 模型的交通标志检测[J]. 激光与光电子学进展, 2020, 57(18): 181-191.
ZHANG Yi, GONG Zhi-yuan, WEI Wen-wen. Traffic sign detection based on improved faster R-CNN model[J]. Laser & Optoelectronics Progress, 2020, 57(18): 181-191.
- [4] 徐国整,周越,董斌,等. 基于改进 Cascade R-CNN 的交通标志牌识别[J]. 传感器与微系统, 2021, 40(5): 142-145.
XU Guo-zheng, ZHOU Yue, DONG Bin, et al. Traffic signs recognition based on improved Cascade R-CNN[J]. Transducer and Microsystem Technologies, 2021, 40(5): 142-145.
- [5] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.
- [6] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 6517-6525.
- [7] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. Computer Vision and Pattern Recognition, 2018, 276(7): 126-134.
- [8] ALEXEY B, WANG C Y, HONG Y. YOLOV4: optimal speed and accuracy of object detection [J]. Computer Vision and Pattern Recognition, 2020, 10(9): 34-51.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C]//European Conference on Computer Vision. Cham: Springer, 2016: 21-37.
- [10] ZHOU K, ZHAN Y, FU D. Learning region-based attention network for traffic sign recognition[J]. Sensors, 2021, 21(3): 686.
- [11] 李世裴,李春琳,韩家哺,等. 面向机器人抓取的双目视觉单步多目标检测方法应用研究[J]. 重庆工商大学学报(自然科学版), 2021, 38(5): 68-74.
LI Shi-pei, LI Chun-lin, HAN Jia-bu, et al. Application of binocular vision single step multi-target detection method for robot grasping[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2021, 38(5): 68-74.
- [12] 张学锋,王子琦,汤亚玲. 基于 YOLO-CDF 神经网络的安全帽检测[J]. 重庆工商大学学报(自然科学版), 2022, 39(4): 32-41.
ZHANG Xue-feng, WANG Zi-qi, TANG Ya-ling. Helmet detection based on YOLO-CDF neural network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(4): 32-41.
- [13] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 936-944.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[M]//Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [16] 霍爱清,南思媛,胥静蓉. 改进 YOLOX 的弱光线道路交通标志检测[J]. 电子测量技术, 2023, 46(6): 62-67.
HUO Ai-qing, NAN Si-yuan, XU Jing-rong. Improved YOLOX's low-light road traffic sign detection[J]. Electronic Measurement Technology, 2023, 46(6): 62-67.

责任编辑:代小红