

基于改进Faster R-CNN的交通标志检测算法

李哲, 张慧慧, 邓军勇

引用本文:

李哲, 张慧慧, 邓军勇. 基于改进Faster R-CNN的交通标志检测算法[J]. 液晶与显示, 2021, 36(3): 484-492.

LI Zhe, ZHANG Hui-hui, DENG Jun-yong. Traffic sign detection algorithm based on improved Faster R-CNN[J]. *Chinese Journal of Liquid Crystals and Displays*, 2021, 36(3): 484-492.

在线阅读 View online: <https://doi.org/10.37188/CJLCD.2020-0195>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度可分离卷积的交通标志识别算法

Traffic sign recognition algorithm based on depthwise separable convolutions

液晶与显示. 2019, 34(12): 1191-1201 <https://doi.org/10.3788/YJYXS20193412.1191>

基于LeNet-5的卷积神经图像识别算法

Convolutional neural image recognition algorithm based on LeNet-5

液晶与显示. 2020, 35(5): 486-490 <https://doi.org/10.3788/YJYXS20203505.0486>

基于Faster R-CNN的仪表识别方法

Instrument recognition method based on Faster R-CNN

液晶与显示. 2020, 35(12): 1291-1298 <https://doi.org/10.37188/YJYXS20203512.1291>

多尺度特征融合与极限学习机结合的交通标志识别

Traffic sign recognition based on multi-scale feature fusion and extreme learning machine

液晶与显示. 2020, 35(6): 572-582 <https://doi.org/10.3788/YJYXS20203506.0572>

基于改进YOLOv3的棉花异性纤维检测

Detection of foreign fiber in cotton based on improved YOLOv3

液晶与显示. 2020, 35(11): 1195-1203 <https://doi.org/10.37188/YJYXS20203511.1195>

文章编号:1007-2780(2021)03-0484-09

基于改进 Faster R-CNN 的交通标志检测算法

李 哲*, 张慧慧, 邓军勇

(西安邮电大学 电子工程学院, 陕西 西安 710121)

摘要:针对大视野交通场景下背景复杂和交通标志目标较小的问题,提出一种改进 Faster R-CNN 检测网络的算法。首先采用深度残差网络 ResNet50 作为骨干网络,提取交通标志的特征;然后设计了在两个不同层级特征图上使用合理尺度滑动窗口的策略来生成目标建议区域,增强多尺度交通标志的检测能力;最后在残差块中引入注意力机制模块,强化图像的关键信息,抑制图像的背景信息。在中国交通标志数据集上验证了算法的有效性,取得了 98.52% 的平均检测精度和每幅图像 0.042 s 的检测速率。本文算法检测效果明显优于原 Faster R-CNN 检测方法,更适用于复杂场景下的交通标志检测,鲁棒性较强。

关键词:交通标志检测;Faster R-CNN;残差网络;目标建议区域;注意力机制

中图分类号:TP391.41 **文献标识码:**A **doi:**10.37188/CJLCD.2020-0195

Traffic sign detection algorithm based on improved Faster R-CNN

LI Zhe*, ZHANG Hui-hui, DENG Jun-yong

(School of Electronic Engineering, Xi'an University of Posts
and Telecommunications, Xi'an 710121, China)

Abstract: Aiming at the problems of complex background and small traffic sign target in large view traffic scene, an improved Faster R-CNN detection network algorithm is proposed. Firstly, the deep residual network ResNet50 is used as the backbone network to extract the features of traffic signs. Secondly, the strategy of using reasonable scale sliding window on two different level feature maps is designed to generate the target proposal region to enhance the detection ability of multi-scale traffic signs. Finally, the attention mechanism module is introduced into the residual block to strengthen the key information of the image and suppress the image background information. The validity of the algorithm is verified on the Chinese traffic sign dataset, with an average detection accuracy of 98.52% and a detection rate of 0.042 s per image. The detection effect of the improved algorithm is obviously better than the original Faster R-CNN detection method, and is more suitable for traffic sign detection in complex scenes, with strong robustness.

Key words: traffic sign detection; Faster R-CNN; residual network; target proposal region; attention mechanism

收稿日期:2020-08-23;修订日期:2020-10-02.

基金项目:国家自然科学基金(No.61602377)

Supported by National Natural Science Foundation of China(No.61602377)

* 通信联系人, E-mail:xytx03@xupt.edu.cn

1 引言

近年来,随着全球汽车数量的逐渐增加,高级辅助驾驶系统(Advanced Driver Assistance System, ADAS)迎来了新的发展机遇。道路交通标志检测与识别^[1]作为ADAS的关键技术,可以指导辅助驾驶员做出相应驾驶决策,减少交通事故的发生。因此,真实路况下及时并准确地检测出交通标志,对辅助驾驶、无人驾驶具有重要的现实意义。

传统的交通标志检测方法主要有RGB^[2]、HSV^[3]颜色空间、形状特征匹配法^[4]、Hough变换法^[5]等,都能够取得较好的检测结果。但这些方法极易受到标志破损、图像倾斜扭曲、光照变化等因素的干扰,造成错误检测。另外,陈龙等人^[6]首先提取交通标志的局部二值化(LBP)和梯度方向直方图(HOG)特征,然后使用支持向量机SVM^[7]、AdaBoost^[8]等特定的分类算法实现交通标志的分类检测。虽然这种方法鲁棒性较强,但泛化能力薄弱,检测时间长,无法满足实时性的要求。近年来,基于深度学习^[9]的交通标志检测算法^[10]以其优异的性能逐渐取代了传统的多类别目标检测方法。Girshick等人首先提出了一种基于区域的卷积神经网络R-CNN^[11]。随后,又提出了Fast R-CNN^[12]和Faster R-CNN^[13]算法。Faster R-CNN采用区域建议网络(RPN)结构替代选择性搜索获取目标候选区域^[14],然后送入Fast R-CNN网络识别目标类别,在检测速度和精度上都有明显提升。此外,王超等人^[15]提出基于You Only Look Once(YOLO)的交通标志检测算法,将特征图等分为 $n \times n$ 个网格,然后预测每个网格区域内的目标。宋青松等人^[16]运用一种聚类残差Single Shot multiBox Detector(SSD)算法实现交通标志检测,在提取多个候选窗口的基础上,增加了 K 均值聚类的思想。这两种单阶段目标检测方法虽然在检测速度上有所突破,但在检测精度上并不优于Faster R-CNN。尤其是对于复杂场景下的小目标检测问题,仍然存在较大的缺失和错误检测。

本文综合考虑交通标志小目标的敏感性和检测速度,选取Faster R-CNN为基本检测模型并加以改进,实现自然场景道路下交通标志的精准

检测。将原始Faster R-CNN模型中的基础网络替换为深度残差网络ResNet50^[17]来提取交通标志的特征;设计了多尺度区域建议网络(Multi Scale Region Proposal Network, MS-RPN)结构生成目标建议区域;并在残差单元中嵌入轻量级注意力机制模块^[18](Convolutional Block Attention Module, CBAM),在不显著增加参数量和计算量的同时,大幅提升了交通标志的检测效果。

2 Faster R-CNN 网络结构的改进

2.1 网络整体结构

由于自然交通场景图像中,交通标志目标尺寸差异较大,导致原始Faster R-CNN检测算法效果不佳,产生漏检和误检的现象。改进后的Faster R-CNN检测网络结构如图1所示。采用50层深度残差网络作为交通标志图像的特征提取器,虽然加深了网络的深度,但是算法复杂度较低,且更大程度地提取和保留了图像中的细小特征。另外,残差网络采用“shortcut”的连接方式构建了一个恒等映射,有效地避免了模型出现过拟合和梯度消失的问题。CBAM模块嵌入在对




图1 改进后的Faster R-CNN网络结构图

Fig.1 Improved Faster R-CNN network structure

检测结果影响较大的卷积层组 ResNet_2、ResNet_3 和 ResNet_4 后。分别在网络的第 3 个卷积层组 ResNet_3 和第 4 个卷积层组 ResNet_4 后接入 MS-RPN 结构,生成不同尺寸交通标志目标的初始建议区域。随后经过兴趣区域池化网络 (ROI Pooling) 层将特征图分块池化为固定尺寸大小,并送入到第 5 个卷积组 ResNet_5 作为目标检测的全连接层,最终判别出目标建议区域属于交通标志还是背景。

2.2 多尺度区域建议网络结构

全景道路图像中包含多个不同尺度的交通标志目标,原始 RPN 仅在特征图的最后一个卷积层上,用 3×3 大小的滑动窗口进行卷积操作获得目标初始建议区域。如果直接使用该算法,会限制模型的感受野,丢失许多小目标特征,从而导致算法性能下降。文献[19]提出了一种多尺度深度卷积神经网络 (Multi Scale Deep Convolutional Neural Network, MS-CNN) 用于快速检测多尺度目标。该方法包括目标建议网络和精确检测网络两个子网络。在目标建议子网络中,分别用卷积层 conv3、conv5 来检测小目标物体和大目标物体,实现了很高的检测率。与该文献方法思路类似,本文设计的 MS-RPN 结构如图 2 所示。




图 2 MS-RPN 结构图

Fig.2 Structure diagram of MS-RPN

对于不同尺度的交通标志目标,采用在 ResNet_3 和 ResNet_4 两个卷积组的最后一层上设置多个滑动窗口的策略生成目标建议区域。在 ResNet_3d 上添加大小分别为 1×1 、 3×3 和 5×5 的滑动窗口,并作为特征映射图用于检测中小尺寸的交通标志。在 ResNet_4f 上添加大小为 5×5 、 7×7 、 9×9 的滑动窗口,并作为特征映射图用于提取中大尺度的标志目标。

2.3 注意力机制模块

自然道路场景中,交通标志与树木、电线杆、广告牌等诸多复杂背景内容叠加在一起,导致算法检测精确率不高。为了提升模型对交通标志目

标与其他背景内容的区分能力,在残差网络的基础上,引入了 CBAM 模块。CBAM 模块可根据特征图内不同区域对不同目标的贡献率不同,舍弃对关键目标贡献率低的特征,保留关键目标的重要特征信息。结合残差结构的 CBAM 结构如图 3 所示。




图 3 结合残差结构的 CBAM 结构图

Fig.3 Structure diagram of CBAM combined with residual structure

CBAM 模块加在卷积块后,由通道注意力机制 (Channel Attention, CA) 和空间注意力机制 (Spatial Attention, SA) 两个模块级联构成。给定一个中间特征输入图 $F \in R^{H \times W \times D}$ (H 、 W 、 D 分别表示特征图的高度、宽度和通道数),依次经过通道注意力模块和空间注意力模块,生成一维通道注意力图谱 $M_c \in R^{1 \times 1 \times D}$ 和二维空间注意力图谱 $M_s \in R^{H \times W \times 1}$,得到最后的输出。具体操作可用公式表示为

$$F' = (M_c(F) + 1) \otimes F, \quad (1)$$

$$F'' = (M_s(F') + 1) \otimes F', \quad (2)$$

式中: $\otimes$ 是逐像素相乘运算符, F' 和 F'' 分别代表经过通道注意力优化和空间注意力优化后的特征图。每个注意力图乘以输入特征图之前均有加 1 操作,是为了避免网络模型因加入注意力模块而导致特征提取性能下降的问题。注意力机制模块能够快速地从大量特征信息图中筛选定位出高价值的目标信息,可有效改善交通标志误检和漏检现象。

2.3.1 通道注意力子模块

中间特征图的每一个通道都可以被视为特征检测器,且不同的通道特征对目标关键信息的贡献率不同^[20]。而通道注意力模块能够通过给特征图赋权的方式筛选出贡献率大的卷积通道,舍弃无效卷积通道,如图 4 所示。

为了有效学习到贡献率较大的卷积通道,首先对输入的特征图 F 采用最大池化 (Max Pooling) 和平均池化 (Avg Pooling) 的方式进行压缩操作,分别




图 4 通道注意力结构图

Fig.4 Structure diagram of channel attention

得到两个包含有全局感受野的通道特征 F_{Max}^C 和 F_{Avg}^C 。其中,Max Pooling 有利于推断目标对象在通道方面的注意力,而 Avg Pooling 能够有效学习目标特征图的每一个像素特征。然后使用多层感知机 (Multilayer Perceptron, MLP) 进行通道权重调整,更好地拟合两个不同空间背景通道间的复杂性。最后将调整得到的两个特征逐元素相加合并为一个一维矢量送入 Sigmoid 函数激活,得到最终的通道注意力图谱 $M_C(F)$ 。整个通道注意力过程的表达式为:

$$M_C(F) = \sigma(\text{MLP}(\text{MaxPool}(F)) + \text{MLP}(\text{AvgPool}(F))) = \sigma(W_1(W_0(F_{\text{Max}}^C)) + W_1(W_0(F_{\text{Avg}}^C))) \quad (3)$$

式中: σ 表示 Sigmoid 激活函数, W_0 和 W_1 是 MLP 的权重参数,在 W_0 后使用了 Relu 非线性激活函数。

2.3.2 空间注意力子模块

相比于通道注意力,空间注意力模块的作用是筛选出所有位置特征中对关键目标贡献率大的空间特征信息。例如对于摆放在广告牌旁边的交通标志,交通标志是主要目标对象,广告牌是其他背景信息。空间注意力机制能够有效关注到交通标志的位置信息而抑制广告牌信息,从而提高检测精度。




图 5 空间注意力结构图

Fig.5 Structure diagram of spatial attention

如图 5 所示,空间注意力机制把输出的通道特征图作为输入,首先采用 Max Pooling 和 Avg Pooling 进行通道维度上的压缩,生成两个不同的二维空间特征描述 F_{Max}^S 和 F_{Avg}^S 。然后沿着通道维度将两个特征叠加融合为二维空间注意力特

征。随后经过 7×7 大小的卷积进行降维操作,得到维度一致的特征图后送入 Sigmoid 函数激活,形成最终的空间注意力图谱 $M_S(F)$ 。整个空间注意力过程的表达式为:

$$M_S(F) = \sigma(f^{7 \times 7}([\text{MaxPool}(F); \text{AvgPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{Max}}^S; F_{\text{Avg}}^S])) \quad (4)$$

式中: σ 表示 Sigmoid 激活函数, $f^{7 \times 7}$ 表示卷积核大小为 7×7 的卷积层。

3 实验结果与分析

3.1 实验环境与数据集

实验所使用的计算机硬件配置为 NVIDIA GTX 1080TI GPU。软件环境为 Ubuntu16.04 操作系统、Caffe 深度学习框架和 Python 编程环境。整个网络的训练损失函数继续沿用原 Faster R-CNN 中的分类损失和回归损失函数公式。网络训练的初始学习率设为 0.001, 动量 (Momentum) 和权重衰减系数 (Weight decay) 分别设为 0.9 和 0.000 5, 用随机梯度下降 (SGD) 算法优化进行端到端的训练。

选取公开的中国交通标志检测数据集 TS-DD^[21] 作为网络改进前后对比实验的基准数据集。该数据集来自北京交通大学重点实验室, 由 10 000 张自然交通场景图像组成, 每张图像的尺寸在 $640\text{pixel} \times 420\text{pixel}$ 到 $3\,096\text{pixel} \times 4\,128\text{pixel}$ 之间, 图中每个交通标志的尺寸在 $16\text{pixel} \times 18\text{pixel}$ 到 $188\text{pixel} \times 192\text{pixel}$ 之间。它们是在不同的地区、时间、天气光照以及运动模糊条件下拍摄所的, 更符合我国实际交通任务的需要, 部分样本如图 6 所示。实验选取其中 4 600 张作为训练样本、2 000 张作为测试样本, 并把交通标志按照指示标志 (Direction)、警告标志 (Caution)、禁止标志 (Prohibition) 分为 3 大类别。

3.2 性能评价指标

实验采用的模型评价指标 mAP 为 3 类交通标志的平均精度 (Average Precision, AP) 均值。平均精度是精确率 (Precision, P) 和召回率 (Recall, R) 所构成的 P - R 曲线与横纵坐标轴所围成的面积, 积分表达式为:

$$\text{AP} = \int_0^1 P(R) dR \quad (5)$$



图 6 数据集样本图
Fig.6 Sample dataset

精确率 P 为检测出的所有交通标志中,检测正确的正样本(交通标志)所占的比例,表达式为:

$$P = \frac{X_{TP}}{X_{TP} + X_{FP}} \quad (6)$$

召回率 R 为样本中的所有交通标志中,检测正确的正样本所占的比例,表达式为:

$$R = \frac{X_{TP}}{X_{TP} + X_{FN}} \quad (7)$$

式中: X_{TP} 表示交通标志被检测为正样本, X_{FP} 表示负样本(背景)被检测为正样本, X_{FN} 表示交通标志被检测为负样本。网络检测速率的评价指标为检测每幅图像所需的时间。当检测到的交通标志边框与真实边框的 IOU(交并比)阈值大于 0.7 时,将检测结果记为正样本;当检测到的交通标志边框与真实边框的 IOU 阈值小于 0.3 时,将检测结果记为负样本。

3.3 结果与分析

算法改进前后所得的 P - R 曲线结果如图 7 所

示。可以看出,改进后的算法曲线下所包围的面积大于原 Faster R-CNN 算法曲线下所包围的面积。即改进后的模型检测精确率高于原 Faster R-CNN 方法。分别对 MS-RPN 结构和 CBAM 模块在 3 类交通标志上进行实验,检测性能结果对比如表 1 所示。




图 7 算法改进前后的 P - R 曲线对比图
Fig.7 P - R curve comparison before and after algorithm improvement

由表 1 可知,与原始 Faster R-CNN 相比,采用深度残差 ResNet50 作为交通标志的基本检测网络和 MS-RPN 结构的设置,平均检测精度提升了 3.82%。由此可知,加深网络的深度,在不同层级上设置不同大小的滑动窗口获得了更精准的候选区域,能够提升网络对不同尺寸交通标志目标的检测能力,且检测每幅图像所需的时间减少了 0.014 s。CBAM 模块的引入优化了网络模型,促进了特征图之间的信息流动,在没有额外增加检测时间的基础上,平均检测精度提升了 2.34%。

表 1 检测性能结果对比表

Tab.1 Comparison of test performance results

Method	Direction(AP)/%	Caution(AP) /%	Prohibition (AP)/%	mAP /%	Time/s · 幅 ⁻¹
Faster R-CNN	92.41	92.23	92.44	92.36	0.056
ResNet50 + MS-RPN	96.41	96.45	96.68	96.18	0.042
ResNet50+MS-RPN+CBAM	98.34	98.86	98.36	98.52	0.042

为了验证改进算法的先进性,选取 3 张具有代表性的测试集图片进行交通标志检测。检测结果如图 8 所示。由图 8(a)、(b)、(c)可知,当交通

标志目标较小时,原 Faster R-CNN 算法存在严重的漏检现象,而改进后的方法可以精确地检测出小目标交通标志。由图 8(d)、(e)、(f)可以看

出,原Faster R-CNN方法没有把存在遮挡情况的交通标志正确检测出来,而改进后的Faster R-CNN方法可以精确检测出存在遮挡现象的交通标志目标。由图8(g)、(h)、(i)可知,面对夜晚光

线较暗的情况,原Faster R-CNN方法、本文方法均能检测到交通标志,但原Faster R-CNN方法的检测精确率为91.6%,且误把车牌检测为交通标志,而本文改进后的方法检测精确率为99.5%。



图8 部分样本检测结果对比图

Fig.8 Comparison of test results of some samples

除了验证网络结构细节上的提升,本文也与其他方法开展横向实验对比,如LBP+SVM方法,SSD模型和YOLOv3模型,实验结果如表2所示。根据表2,首先提取交通标志的LBP特征,然后使用SVM实现交通标志分类检测方法的平均检测精度为88.67%,检测每幅图像的时间为0.13 s,远远慢于其他方法。对于单阶段检测网络模型SSD

和YOLOv3,由于采用默认窗口机制,不依赖于候选区域,所以检测速度较快,但检测精度仍然低于本文方法。本文方法在测试集上的平均检测精度为98.52%,检测速度为0.042 s/幅,依然达到实时检测的范围。所以,本文提出的基于改进Faster R-CNN的网络方法在交通标志检测任务是可行的。各种方法的检测结果如图9所示。

表 2 各实验方法检测结果对比表

Tab.2 Comparison table of test results of each experimental method

Method	Datasets	Direction(AP)/%	Caution(AP) /%	Prohibition (AP)/%	mAP /%	Time/s · 幅 ⁻¹
LBP+SVM	TSDD	88.69	88.65	88.67	88.67	0.13
SSD		93.75	93.27	94.05	93.69	0.028
YOLOv3		93.41	9.12	94.89	94.14	0.026
本文方法		98.34	98.86	98.36	98.52	0.042




图 9 各方法检测结果图
Fig.9 Test result diagram of each method

4 结 论

针对复杂背景条件下的中国交通场景图像,本文改进了原 Faster R-CNN 目标检测算法。使用结合注意力机制的残差 ResNet50 作为交通标志的特征提取器,提升了小目标交通标志的特征表征能力。

另外,设计了在两个不同层级上采用合理尺度滑动窗口的策略,获取了不同尺度目标的精准候选区域,改善了多尺度交通标志的检测能力。通过实验证明,本文改进后的方法使得 Faster R-CNN 检测网络对交通标志的检测性能有了明显的提升,平均检测精确率由 92.36% 提高到了 98.52%。能够较好地适应真实道路环境下的交通标志目标检测任务。

参 考 文 献:

[1] 杨晋生,杨雁南,李天骄. 基于深度可分离卷积的交通标志识别算法[J].液晶与显示,2019,34(12):1191-1201.
YANG J S, YANG Y N, LI T J. Traffic sign recognition algorithm based on depthwise separable convolutions [J].
Chinese Journal of Liquid Crystals and Displays, 2019, 34(12): 1191-1201. (in Chinese)

[2] SURINWARANGKOON T, NITSUWAT S, MOORE E J. Traffic sign recognition by color filtering and particle swarm optimization [C]//*Proceedings of the 2012 4th International Conference on Computer Research and Devel-*

- opment. Singapore: IACSIT Press, 2012: 58-62.
- [3] CHEN Y X, XIE Y, WANG Y L. Detection and recognition of traffic signs based on HSV vision model and shape features [J]. *Journal of Computers*, 2013, 8(5): 1366-1370.
 - [4] KHAN J F, BHUIYAN S M A, ADHAMI R R. Image segmentation and shape analysis for road-sign detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2011, 12(1): 83-96.
 - [5] MEUTER M, NUNN C, GORMER S M, *et al.* A decision fusion and reasoning module for a traffic sign recognition system [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2011, 12(4): 1126-1134.
 - [6] 陈龙,潘志敏,毛庆洲,等. 利用 HOG-LBP 自适应融合特征实现禁令交通标志检测[J]. 武汉大学学报·信息科学版, 2013, 38(2): 191-194.
CHEN L, PAN Z M, MAO Q Z, *et al.* HOG-LBP adaptable fused features based method for forbidden traffic signs detection [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(2): 191-194. (in Chinese)
 - [7] GROLEAT T, ARZEL M, VATON S. Stretching the edges of SVM traffic classification with FPGA acceleration [J]. *IEEE Transactions on Network and Service Management*, 2014, 11(3): 278-291.
 - [8] CHEN T, LU S J. Accurate and efficient traffic sign detection using discriminative AdaBoost and support vector regression [J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(6): 4006-4015.
 - [9] 黄乐弘,曹立华,李宁,等. 深度学习的空间红外弱小目标状态感知方法[J]. 中国光学, 2020, 13(3): 527-536.
HUANG L H, CAO L H, LI N, *et al.* A state perception method for infrared dim and small targets with deep learning [J]. *Chinese Optics*, 2020, 13(3): 527-536. (in Chinese)
 - [10] 童英,杨会成. 基于改进卷积神经网络的实时交通标志检测方法[J]. 激光与光电子学进展, 2019, 56(7): 071003.
TONG Y, YANG H C. Real-time traffic sign detection method based on improved convolution neural network [J]. *Laser & Optoelectronics Progress*, 2019, 56(7): 071003. (in Chinese)
 - [11] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation [C]//*Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014: 580-587.
 - [12] GIRSHICK R. Fast R-CNN [C]//*Proceedings of 2015 IEEE International Conference on Computer Vision*. Santiago: IEEE, 2015: 1440-1448.
 - [13] 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.
 - [14] 王春哲,安军社,姜秀杰,等. 基于卷积神经网络的候选区域优化算法[J]. 中国光学, 2019, 12(6): 1348-1361.
WANG C Z, AN J S, JIANG X J, *et al.* Region proposal optimization algorithm based on convolutional neural networks [J]. *Chinese Optics*, 2019, 12(6): 1348-1361. (in Chinese)
 - [15] 王超,付子昂. 基于 YOLO v2 模型的交通标识检测算法[J]. 计算机应用, 2018, 38(S2): 276-278.
WANG C, FU Z A. Traffic sign detection based on Yolo v2 model [J]. *Journal of Computer Applications*, 2018, 38(S2): 276-278. (in Chinese)
 - [16] 宋青松,王兴莉,张超,等. 用于交通标志检测的窗口大小聚类残差 SSD 模型[J]. 湖南大学学报(自然科学版), 2019, 46(10): 133-140.
SONG Q S, WANG X L, ZHANG C, *et al.* A residual SSD model based on window size clustering for traffic sign detection [J]. *Journal of Hunan University (Natural Sciences)*, 2019, 46(10): 133-140. (in Chinese)
 - [17] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition [C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 770-778.
 - [18] WOO S, PARK J, LEE J Y, *et al.* CBAM: convolutional block attention module [C]//*Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer, 2018: 3-19.
 - [19] CAI Z W, FAN Q F, FERIS R S, *et al.* A unified multi-scale deep convolutional neural network for fast object detection [C]//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam: Springer, 2016: 354-370.
 - [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 7132-7141.

- [21] Chinese traffic sign database[DB/OL]. (2017-02-20)[2020-05-12]. <http://www.nlpr.ia.ac.cn/pal/trafficdata/detection.html>.

作者简介:



李 哲(1963—),男,陕西西安人,硕士,教授,1987 年于西北工业大学获得硕士学位,主要从事图形图像处理与嵌入式系统方面的研究。E-mail: xytx03@xupt.edu.cn