

一种复杂场景下高精度交通标志检测模型

李嘉豪¹, 闵卫东^{1,2,3}, 陈炯缙¹, 朱梦¹, 展国伟¹

(1. 南昌大学 数学与计算机学院, 南昌 330031; 2. 南昌大学 元宇宙研究院, 南昌 330031;

3. 江西省智慧城市重点实验室, 南昌 330031)

摘要: 交通标志检测在智能交通领域的安全保障上具有重要作用。对于部分外观相似的交通标志在尺度变化下, 现有模型难以提取它们之间的细微差异, 导致标志被错误分类。此外, 在复杂场景下, 其他相似物体容易被误检为交通标志。为此, 提出一种逐层特征细化检测模型。根据交通标志特点提出分层聚类锚框和分组损失, 分层聚类锚框根据目标尺度对数据集分层并通过 K-means 聚类算法获取各层锚框, 更好地适应交通标志灵活的尺度变化, 分组损失对外观相似的类别分组并设计损失函数, 指导模型学习相似交通标志间的细微差距, 从而降低错误分类。在 Neck 层加入弱语义分割模块和特征细化模块, 通过弱语义分割模块学习浅层特征上下文信息, 从而分割出可信区域和非可信区域, 利用特征细化模块挖掘非可信区域的上下文信息, 主动学习并消除造成误检的干扰, 从而降低对其他相似物体的误检。弱语义分割模块和特征细化模块结合通道注意力构建逐层细化特征金字塔, 实现对多尺度特征的整体优化并提高模型精确率。实验结果表明, 该方法在 TT100K 和 GTSDb 交通标志数据集上的 AP₅₀ 指标分别达到 97.0% 和 98.6%。

关键词: 交通标志检测; 复杂场景; 分层聚类锚框; 分组损失; 弱语义分割模块; 特征细化模块

开放科学(资源服务)标志码(OSID):



中文引用格式: 李嘉豪, 闵卫东, 陈炯缙, 等. 一种复杂场景下高精度交通标志检测模型[J]. 计算机工程, 2023, 49(11): 311-320.

英文引用格式: LI J H, MIN W D, CHEN J J, et al. A high precision traffic sign detection model in complex scenes[J]. Computer Engineering, 2023, 49(11): 311-320.

A High Precision Traffic Sign Detection Model in Complex Scenes

LI Jiahao¹, MIN Weidong^{1,2,3}, CHEN Jiongjin¹, ZHU Meng¹, ZHAN Guowei¹

(1. School of Mathematics and Computer Science, Nanchang University, Nanchang 330031, China;

2. Institute of Metaverse, Nanchang University, Nanchang 330031, China;

3. Jiangxi Key Laboratory of Smart City, Nanchang 330031, China)

[Abstract] In an intelligent transportation system, traffic sign detection plays a crucial role. However, existing models find it difficult to extract the subtle differences between certain signs with similar appearances under scale changes, resulting in misclassification. In addition, in complex scenes, other similar objects are easily mistakenly detected as traffic signs. To this end, a layer-by-layer feature refinement detection model is proposed. Based on the characteristics of traffic signs, a hierarchical clustering anchor box and group loss are developed. The hierarchical clustering anchor box layers the dataset according to the target scale and obtains each anchor box layer by using the K-means clustering algorithm, enabling better adaptation to the flexible scale changes of traffic signs. For group loss, similar appearance categories are grouped and a loss function is designed to guide the model in learning the subtle differences between similar traffic signs, thereby reducing misclassification. A Weak Semantic Segmentation (WSS) module and Feature Refinement Module (FRM) are added in the Neck layer. The WSS module learns shallow feature context information, enabling segmentation of trusted and untrusted regions. The feature refinement module mines the contextual information of untrusted regions, actively learning and eliminating interference that causes false detections, thereby reducing false detections of other similar objects. The two modules combine channel attention to construct a layer-by-layer refinement feature pyramid, achieving overall optimization of multi-scale features and improving model accuracy. The experimental results show that the method performs well on the TT100K and GTSDb traffic sign datasets, with AP₅₀ indicators reaching 97.0% and 98.6%, respectively.

基金项目: 国家自然科学基金(62076117); 江西省智慧城市重点实验室项目(20192BCD40002)。

作者简介: 李嘉豪(1998—), 男, 硕士研究生, 主研方向为深度学习、目标检测; 闵卫东(通信作者), 教授、博士; 陈炯缙, 硕士研究生; 朱梦, 博士研究生; 展国伟, 硕士研究生。

收稿日期: 2022-11-28 **修回日期:** 2023-01-26 **E-mail:** minweidong@ncu.edu.cn

[Key words] traffic sign detection; complex scenes; hierarchical clustering anchor; group loss; Weak Semantic Segmentation(WSS)module; Feature Refinement Module(FRM)

DOI:10.19678/j.issn.1000-3428.0066372

0 概述

随着智能交通领域中自动驾驶等技术不断发展,如何保障交通安全也愈发受到重视。交通标志检测利用快速检测交通标志并将信息传递给智能交通系统,辅助智能交通系统快速了解重要的道路信息,从而保障交通安全。然而,在复杂环境下光照、遮挡、尺度变化、交通标志的形变和褪色等因素都为交通标志检测带来诸多挑战。除此之外,部分交通标志的外观十分相似,模型在尺度变化下难以识别它们之间的特征差异,导致分类错误。此外,在交通场景中存在与交通标志相似的其他物体容易被误检,包括因为距离、模糊等因素而无法区分类别的原交通标志。

传统交通标志检测方法主要基于颜色和形状等手工特征,例如,形状、颜色、HOG、SIFT、边缘等^[1-3]手工特征的方法。但是这些方法在面对上述问题时,往往不能取得较优的检测效果。许多研究人员将卷积神经网络应用于交通标志检测领域,并取得一定的进展。然而,如何提高卷积神经网络的准确性仍然是研究热点。

近年来,基于卷积神经网络的交通标志检测方法成为主流。文献[4]基于YOLOv3提出多尺度注意力模块(Multi-Scale Attention Module, MSAM)融合不同尺度特征,增强网络表示能力,并增加1个检测层以有效利用较浅层的小目标特征。TSingNet^[5]基于RetinaNet提出注意力驱动的双边特征金字塔网络(Attention-driven Bilateral Feature Pyramid Network, ABFPN)和适应性感受野融合(Adaptive Receptive Field Fusion, ARFF)学习尺度感知和上下文信息,有效检测小而遮挡的交通标志。

然而,上述方法主要通过改进整体网络结构和注意力优化特征提取过程,提高小目标的检测效果。现有方法很少关注交通标志数据集的外观特点,尤其是TT100K^[6]数据集,在该数据集分类下的部分交通标志之间有着十分相似的外观,优化网络和改进注意力都难以指导模型学习其中的细微差异。此外,由于其他相似物体尤其是原交通标志具有交通标志的外观特征,因此通过优化网络结构和添加注意力的方式难以有效抑制对这种特征的提取,导致误检。

本文选取综合性能较优的一阶段检测模型RetinaNet^[7]作为主体框架,提出逐层特征细化检测(Layer-by-layer Feature Refinement Detection, LFRD)模型。通过对RetinaNet模型的锚框机制优化设计分层聚类锚框,并根据交通标志外观特点提出分组

损失,有效应对因交通标志尺度变化和相似交通标志的漏检和错误分类问题。此外,设计弱语义分割(Weak Semantic Segmentation, WSS)模块和特征细化模块(Feature Refinement Module, FRM),通过主动学习的方式减少对其他相似物体的误检。WSS利用弱语义分割生成可信区域和非可信区域,FRM利用多尺度信息主动学习并消除非可信区域特征中造成误检的干扰特征,结合通道注意力^[8](SENet)抑制细化特征的背景并增强前景。利用上述方法沿自底向上子网逐层细化特征,构建逐层细化特征金字塔(Layer-by-layer Refinement of Feature Pyramid Network, LRFPN)从而降低误检。

1 相关工作

1.1 基于卷积神经网络的交通标志检测

卷积神经网络的交通标志检测方法主要基于两阶段检测模型和一阶段检测模型。两阶段检测模型是将区域建议与卷积神经网络相结合进行目标检测。经典的两阶段检测模型如Faster R-CNN^[9]、R-FCN^[10]、Cascade R-CNN^[11]、Mask R-CNN^[12]等。文献[13]提出多分支样本金字塔,基于Faster R-CNN,利用图像金字塔和动态卷积适应交通标志的尺度变化。文献[14]基于R-FCN,将符号的位置和大小作为先验知识缩小搜索范围,提出高性能轻量级超类检测器和精化分类器,从而提高检测性能。

虽然两阶段检测模型在交通标志检测中取得优异的性能,但是一阶段检测模型因其更具时效性而成为交通标志检测的主流方法。一阶段检测模型是将目标检测转化为1个回归问题来进行端到端的检测。经典的一阶段检测模型有SSD^[15]、YOLO^[16]、RetinaNet等。文献[17]对YOLOv3^[16]做出一些调整,在此基础上提出1个多尺度注意力特征模块,该模块有助于融合不同层次的特征信息以此对特征进行细化,增强特征金字塔网络性能。文献[18]在改进RetinaNet的基础上级联1个二分类网络,有助于从第一阶段预测结果中识别有效的交通标志,提高准确率。文献[19]基于SSD提出一种基于语义场景理解和结构化交通标志定位的方法,利用空间位置约束减少对其他类似物体的误检。

1.2 基于语义分割的交通标志检测

语义分割是提取图像特征并对特征的每个像素进行分类,从而获取到1张关于图像类别信息的分割图。Mask R-CNN结合FCN中的语义分割技术在经典两阶段检测模型Faster R-CNN的基础上增加1个分支网络作为语义分割的输出。通过共享分支

特征以及修改网络, 在实现目标检测的同时分割目标像素。文献[20]在检测头前加入基于弱语义分割的动态增强附件, 避免提取能力下降, 导致误检、漏检。

1.3 基于特征金字塔的交通标志检测

特征金字塔网络^[21](Feature Pyramid Network, FPN)是利用多尺度特征融合来缓解不同尺度之间语义信息不平衡问题的方法, 可以在不同尺度上检测目标。该方法简单高效, 被用于YOLO系列、RetinaNet等诸多一阶段检测模型中。随着对特征金字塔的深入研究, 自FPN后又出现如路径聚合网络^[22](Path Aggregation Network, PAN)等优秀的特征金字塔方法。文献[5]提出一种注意力驱动的双边特征金字塔, 在尺度注意力学习中双循环低、中、高尺度特征的前景语义信息, 从而提高交通标志的检测效果。

上述现有方案从不同方面对交通标志检测进行改进, 并取得较优的检测效果, 但是大多数方法更加关注对小目标检测效果的提高, 很少关注交通标志外观特点。除此之外, 现有方案大多利用通道注意力或空间注意力对特征进行细化, 从而抑制误检, 这种方式是针对整体进行优化, 对光照和部分相似物体有一定的效果, 但是对与交通标志更相似的其他物体检测效果不佳。本文通过对交通标志数据集的外观特点进行分析, 利用修改损失指导模型学习相

似交通标志之间的差异。另外, 本文不是基于全局优化的方式抑制误检, 而是采用弱语义分割和特征细化模块主动学习和消除造成误检的干扰特征。

2 逐层特征细化检测模型

2.1 模型的整体结构

逐层特征细化检测模型的整体框架: 以ResNet 50^[23]作为特征提取网络, 以特征细化模块和弱语义分割模块结合通道注意力构建的逐层细化特征金字塔来实现多尺度特征优化, 最后以语义分割图调整检测结果。模型输入尺寸为 512×512 像素, 经过8倍、16倍和32倍的下采样倍率得到3种不同尺寸的特征并分别利用 1×1 卷积降低特征维度(P_3 、 P_4 、 P_5), 在模型 Neck 部分将 P_3 输入到弱语义分割模块, 结合最大池化下采样得到不同尺度的语义分割图, 之后将尺度最小的分割图和 P_5 输入到特征细化模块获取细化特征 $F_{r,5}$ 和输出特征 $F_{out,5}$ 。将 $F_{out,5}$ 输入检测头中得到该层检测结果, 将 $F_{r,5}$ 上采样并利用通道注意力抑制背景增强前景, 实现浅层特征和深层语义特征的融合。在其余2层中重复上述过程, 实现自底向上逐层细化的效果。除此之外, $F_{r,5}$ 利用 3×3 卷积下采样作为第4层检测头的输入, 在获取到检测结果时, 利用语义分割图调整置信度实现对结果的优化。LFRD模型的结构如图1所示。




图1 逐层特征细化检测模型整体结构

Fig.1 Overall structure of layer-by-layer feature refinement detection model

2.2 分层聚类锚框与分组损失

RetinaNet使用平移不变锚框, 类似于文献[21]中RPN变体的锚框。锚框在金字塔层次 $P_3 \sim P_7$ 上的面积分别为 $32^2 \sim 512^2$ 。但是平移不变锚框难以适应尺寸小且尺度灵活多变的交通标志, 尤其是交通标志中有大量面积小于 32^2 的实例。通过分析TT100K数据集的训练集, 其中面积小于 32^2 的正样本(模型的锚框和标签框交并比大于0.5)占17.5%, 最小尺度的交通标志仅有72像素。针对该问题, 本文提出一种分层聚类锚框方法, 使不同检测层检测适合尺度的目标。参考RetinaNet为每层分配的尺度和比例分别为

$\{32^2, 64^2, 128^2, 256^2, 512^2\}$ 和 $\{2^0, 2^{\frac{1}{3}}, 2^{\frac{2}{3}}\}$, 为每个检测层重新规划检测区域, 每层的最小尺寸为 $\{0, 32^2, 64^2, 128^2, 256^2\}$, 最大尺寸为 $\{32^2, 64^2, 128^2, 256^2, 512^2\} \times 2^{\frac{2}{3}}$ 。因为满足第5层条件的样本数量太少, 所以在去掉第5层的同时将第4层的最大尺寸增大为 512^2 。

分层聚类锚框结构如图2所示。计算训练数据集中交通标志的长宽, 根据每层检测区域的范围将交通标志按照所属层次分组为多个子集, 分别利用K-means聚类算法对不同子集进行分析, 选择各层对应合适的锚框数。本文选择每层锚框数为3。




图2 分层聚类锚框结构

Fig.2 Structure of hierarchical clustering anchors

除此之外,RetinaNet采用Focal loss作为分类损失,该损失能有效改善TT100K中类不平衡的问题,但并不能指导模型学习相似交通标志之间的细微差异,导致分类错误。

在TT100K数据集中的功能类别和相似案例如图3所示(彩色效果见《计算机工程》官网HTML版)。TT100K数据集按照功能将标志分为禁止(P)、建议(I)、警告(W)3大超类。同一超类下的交通标志颜色和形状都更加相似,禁止(P)多为白底并带有红色圆形边框,建议(I)多为蓝底圆形边框,警告(W)多为黄底三角形边框。




图3 在TT100K数据集中的功能类别和相似案例

Fig.3 Functional categories and similar cases in TT100K dataset

从图3的右边可以看出,受距离和光照影响,同超类下的交通标志细节更模糊,容易误检,尤其是包含多个稀少类别的io、po、wo 3类。在TT100K数据集中有221个类别,其中大量类别的实例数量稀少甚至只有个位数,TT100K数据集^[6]将数量稀少的类别按功能(I、P、W)统一为io、po、wo 3类。

针对这个问题,本文根据交通标志类别功能设计分组损失函数,定义如式(1)和式(2)所示:

$$l_{\text{group}} = \sum_{i=1}^3 l_{\text{ce}}(\theta(p_i), \hat{p}_i) \quad (1)$$

$$l_{\text{ce}}(p_i, \hat{p}_i) = \begin{cases} -\sum_{j=1}^{c_i} \hat{p}_{i,j} \ln p_{i,j}, & \sum_{j=1}^{c_i} \hat{p}_{i,j} = 1 \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中: p_i 和 $\hat{p}_i$ 为按照功能类别划分为3组的预测和标签; θ 为Softmax激活函数; c_i 为第*i*组的类别总数; $p_{i,j}$ 和 $\hat{p}_{i,j}$ 分别代表 p_i 和 $\hat{p}_i$ 内第*j*位预测和标签的结果;条件 $\sum_{j=1}^{c_i} \hat{p}_{i,j} = 1$ 保证了该损失仅在正样本的时候才会起到效果。将外观特征相似的交通标志类别放在同

一组并分别计算损失函数,借助Softmax局部注意力放大的效果,有利于在同组下突出不同类之间的差异并指导模型学习这种差异,减少交通标志的分类错误。

2.3 逐层细化特征金字塔

逐层细化特征金字塔(LRFPN)是在特征金字塔的基础上包含1个弱语义分割模块、2个通道注意力模块、3个特征细化模块。采用自下而上的子网,结合弱语义分割和特征细化模块学习并消除底层特征对误检产生的干扰,从而获取细化特征和输出特征,利用通道注意力抑制细化特征的背景并增强前景,沿着子网迭代细化过程,以实现对整个特征金字塔的优化,从而降低对其他相似物体的误检。

2.3.1 自适应多尺度探索模块

弱语义分割模块和特征细化模块都需要学习目标的上下文信息,为此,本文设计1个自适应多尺度探索模块。该模块由自适应权重(Adaptive Weights, AW)和轻量级多尺度方案组成,能够在像素级层面上自适应地控制网络感受野,以获取丰富的上下文信息。

自适应多尺度探索模块结构如图4所示。




图4 自适应多尺度探索模块结构

Fig.4 Structure of adaptive multi-scale exploration module

自适应权重和人为分配权重不同,自适应权重并不像后者根据先验知识为不同感受野分配相应权重,而是利用卷积神经网络学习每个像素点特征的周边信息以生成相应的感受野权重,如式(3)所示:

$$W = \theta(C_{7 \times 7}(C_{\text{CBR}}(x))) \quad (3)$$

其中: C_{CBR} 表示 1×1 卷积和Batch_Norm以及ReLU激活函数,用于提取像素点的特征信息并将通道数映射到分支数 $K(K=4)$; $C_{7 \times 7}$ 表示 7×7 大核卷积,用于获取像素点的周边信息; θ 表示Softmax激活函数,获取不同分支的比例。自适应多尺度探索模块利用反向传播和Softmax激活函数增强局部注意的效果,学习像素级感受野分支权重图 W 。

轻量级多尺度探索模块利用通道压缩和分组卷积减少计算量和参数量。FRM使用的自适应多尺度探索模块参数如表 1 所示, 其中 $A \times A$ 表示卷积核大小为 A , r 表示卷积扩张率大小。

表 1 FRM 使用的自适应多尺度探索模块参数

Table 1 Parameters of the adaptive multi-scale exploration module used by FRM

层数	分支 1	分支 2	分支 3	分支 4
1	1×1	3×3	3×3	3×3
2	—	—	3×3, $r=2$	3×3, $r=2$
3	—	—	—	3×3, $r=3$
感受野	1×1	3×3	7×7	13×13

轻量级多尺度探索模块利用 1×1 标准卷积压缩输入特征通道, 其中, FRM 模块和 SSW 模块针对压缩输入特征通道有所不同, 前者压缩通道为原通道数的 50%, 后者压缩通道为原通道数的 25%, 还设计 4 个平行的分组卷积和随后具有不同扩张率的分组扩张卷积层组成感受野分支, 在小标志和大标志之间有效平衡感受野并获取充分的上下文信息。增大的扩张率通过强调上下文内容和大目标来扩大有效感受野, 而减小的扩张率则更倾向于关注小目标。WSS 模块所使用的轻量级多尺度探索模块参数如表 2 所示, WSS 模块所采用的轻量级多尺度探索模块实现感受野范围从 1×1 到 13×13 的变化, 分组数为 16。

表 2 WSS 使用的轻量级多尺度探索模块参数

Table 2 Parameters of the lightweight multi-scale exploration module used by WSS

层数	分支 1	分支 2	分支 3	分支 4
1	3×3	3×3	3×3	5×5
2	—	3×3, $r=2$	3×3, $r=2$	3×3, $r=2$
3	—	—	3×3, $r=2$	3×3, $r=2$
感受野	3×3	7×7	13×13	15×15

自适应多尺度探索模块在得到自适应权重和多条分支的特征后, 对两者进行特征融合, 如式 (4) 所示:

$$F_{out} = C_2 \left(\sum_{i=1}^4 W_i \cdot B_{Branch_i}(C_{CGH}(x)) \right) \quad (4)$$

其中: C_{CGH} 表示 1×1 标准卷积和 GroupNorm 以及 Hardswish 激活函数, 用于压缩特征通道数来提取隐藏特征; B_{Branch_i} 表示提取不同感受野特征的第 i 个感受野分支; W_i 表示由自适应权重模块生成对应分支 i 的权重图; $\cdot$ 表示哈达玛积; C_2 表示恢复通道数的点卷积。

2.3.2 弱语义分割模块与特征细化模块

部分误检是由于交通标志相似的物体造成的, 它们具有交通标志的特征所以难以被模型消除, 能够避免受网络优化和注意力的影响。

针对这个问题, 本文提出特征细化模型, 通过主动学习并消除特征中的干扰来降低误检概率。弱语义分割模块与特征细化模块结构如图 5 所示。




图 5 弱语义分割与特征细化模块结构

Fig.5 Structure of weak semantic segmentation and feature refinement modules

为学习干扰特征, 首先获取干扰的位置, 获取干扰位置的流程如图 5 的左图所示, 本文结合自适应多尺度探索模块和 1 个 7×7 卷积, 提出 1 个弱语义分割模块, 并利用卷积核为 3、步长为 2 的最大池化获取不同尺寸的分割图, 其过程如式 (5) 所示:

$$F_{map} = \text{Conv}_{7 \times 7}(P_3 + S_{SCE}(P_3)) \Rightarrow m_{map_3} = (F_{map} > 0) \quad (5)$$

其中: S_{SCE} 表示基于表 2 中参数的自适应多尺度探索模块, 其感受野范围从 3×3 到 15×15 的变化, 分组

数为 32; P_3 表示通道压缩后的浅层特征; $\text{Conv}_{7 \times 7}$ 表示 7×7 大核卷积将通道数映射为 1, 以阈值为 0 生成分割图, 避免产生反向传播影响到特征细化模块的优化。

语义分割图除了辅助特征细化以外, 还可以作为惩罚模块 (Punishment Module, PM) 对预测结果进行优化, 对位于非可信区域的预测结果进行惩罚, 惩罚系数为 0.5, 如式 (6) 所示:

$$P_{Pred_{p,i}}[1 - m_{map_i}] = p_{Pred_{p,i}}[1 - m_{map_i}] \times 0.5 \quad (6)$$

其中: $P_{Pred_{p,i}}$ 表示第 i 层分支预测结果; m_{map_i} 表示与

第 i 层对应的弱语义分割图,在非可信区域内的预测结果,其置信度都将降低为原先的 50%。

FRM 结构如图 5 的右图所示,在利用弱语义分割图获取到非可信区域特征后, $F_{c,i}$ 是第 i 个模块的输入特征,首先利用上下文信息学习其中的假阳性干扰,然后利用简单的元素相减方式从特征中消除这些干扰从而得到细化特征 $F_{r,i}$,其过程如式(7)所示:

$$F_{r,i} = F_{c,i} - \sigma(C_{CE_{i,1}}(F_{c,i} \times (1 - \text{map}_i))) \quad (7)$$

其中: $F_{c,i}$ 为第 i 层 FRM 模块的输入特征; $C_{CE_{i,1}}$ 表示根据表 1 中参数构建的自适应多尺度探索模块,用于学习非可信区域中的干扰特征; σ 表示 ReLU 激活函数。

将细化后的 $F_{r,i}$ 沿着特征金字塔向上传递的同时利用 1 个新的自适应多尺度探索模块获取细化特征丰富的上下文信息表示 $F_{\text{out},i}$,如式(8)所示:

$$F_{\text{out},i} = F_{r,i} + C_{CE_{i,2}}(F_{r,i}) \quad (8)$$

$CE_{i,2}$ 和 $CE_{i,1}$ 的参数虽然一致但作用不同,前者是为了学习全局上下文信息代替 7×7 标准卷积。

为了避免因数据集过少而造成过拟合问题,从而影响 LRFPN 的检测效果,本文在训练时人为地生成一些干扰信息影响弱语义分割,以 50% 的概率遮挡正样本区域,提高模块保留假阴性干扰的能力,同样以 50% 的概率生成 1 个位置随机且面积在 50%~150% 目标的正向干扰区域,以提高全局挖掘并消除可信区域假阳性干扰的能力。

3 实验与结果分析

3.1 实验数据集与评价指标

本文采用 TT100K^[6] 和德国交通标志检测基准 GTSDDB^[24] 数据集验证实验效果。清华大学和腾讯公司联合制作的数据集 TT100K 是 1 个数量和图像尺度都较大的交通标志基准,由 10 000 个分辨率为 $2\,048 \times 2\,048$ 像素的街景图像和 30 000 个交通标志实例组成,对应 200 多个类别。因为获得难度不同,所以 TT100K 存在类不平衡的现象。参考数据集来源的文献[6],本文挑选大于 100 实例的 42 类别,并根据建议、禁止、警告将其余类别统一成 io、po、wo 3 类,共计 45 类,利用数据增强将低于 1 000 实例的类别扩充至 1 000。GTSDDB 被广泛用于交通标志检测的评价,包括 900 幅分辨率为 $1\,360 \times 800$ 像素的图像(600 幅用于训练,300 幅用于测试)。

本文采用 AP_{50} 、 AP_{75} 、AP、精确率(P)、召回率(R)、F1 值这 6 个指标评价模型性能。 AP_{50} 、 AP_{75} 分别表示交并比 IoU 大于 0.50 和 0.75 时的综合平均精确率

mAP, AP 是 IoU 在 $[0.50:0.05:0.95]$ 下分别计算获得的 mAP,并计算这些结果的均值,为了区分每个类别的平均精度,每个类别的平均精度被设置为 ap。mAP 是计算所有类别 P - R 曲线下面积的平均值,如式(9)所示:

$$m_{\text{mAP}_{\text{iou}}} = \frac{1}{N} \sum_{n=0}^N \int_0^1 P_n(r) dr \quad (9)$$

其中: iou 为设置好的 IoU 阈值; N 为该数据集样本类别数量; P_n 为该样本类别的平均精度值。

F1 值(F_1)是利用精确率和召回率计算获得的综合指标,如式(10)所示:

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (10)$$

3.2 训练策略

本文实验平台设置:CPU 为 Intel Core i9-10900K,内存 64 GB, GPU 为 NVIDIA GeForce RTX P4000,显存 8 GB,操作系统为 Ubuntu 16.04,深度学习框架为 PyTorch。

TT100K 数据集的图像分辨率太大而无法进行训练。为解决这个问题,本文参照文献[25]的图像处理方法,使用大小为 512×512 的滑窗对训练集进行裁剪,滑窗之间的重叠率为 20%,过滤掉包含 0.5 个目标(一个标签所占面积的 50%)以下的子图。GTSDDB 的图像尺寸直接调整为 640×640 像素。

因为添加了弱语义分割,所以利用 IoU 损失 $\ell_{\text{iou}}^{[26]}$ 和二进制交叉熵损失 $\ell_{\text{BCE}}^{[26]}$ 优化分割图,如式(11)所示:

$$L_{\text{map}} = \ell_{\text{iou}} + \ell_{\text{BCE}} \quad (11)$$

为了实现联合训练,结合本文提出的分组损失,总损失的表达式如下:

$$L_{\text{total}} = \lambda_1 L_{\text{reg}} + \lambda_2 L_{\text{cls}} + \lambda_3 L_{\text{group}} + \lambda_4 L_{\text{map}} \quad (12)$$

其中: λ_1 、 λ_2 、 λ_3 、 λ_4 分别为各项损失设置的权重系数; L_{reg} 、 L_{cls} 、 L_{group} 、 L_{map} 分别为回归损失、分类损失、分组损失、弱语义分割损失。

3.3 与其他模型的性能对比

为评估本文提出检测模型 LFRD 对小交通标志检测的能力,在 GTSDDB 数据集上进行实验。通过直接缩小的 GTSDDB 尺寸来满足模型输入的需求,导致 GTSDDB 数据集中的目标小于其原先尺寸,增加了小目标在数据集中的比例。本文方法和其他交通标志检测方法在 GTSDDB 数据集上的实验结果如表 3 所示,加粗表示最优数据, AP_{50} 表示检测的综合结果,禁止、建议、警告表示每个类别在 IoU 阈值为 0.5 时的平均精度 ap。

表 3 不同方法在 GTSDb 数据集上的实验结果

Table 3 Experimental results among different methods on the GTSDb dataset

%

方法	AP ₅₀	ap		
		禁止	建议	警告
文献[17]方法	97.0	99.2	94.4	97.3
ReYOLO ^[27]	97.2	94.4	99.3	97.9
文献[28]方法	81.4	90.3	71.4	82.4
文献[29]方法	96.7	97.9	93.5	98.8
MTSDet ^[30]	92.9	90.9	88.6	99.1
MSE-YOLOv4 ^[31]	97.9	99.5	95.3	98.9
LFRD	98.6	99.8	97.9	98.0

从表 3 可以看出: 本文提出的 LFRD 在 GTSDb 数据集中 3 个类的 ap 中有 1 个取得最优结果, 总体 AP₅₀ 也优于其他方法, 说明 LFRD 即使面对小目标也有较优的检测效果, 与其他方法相比具有一定的竞争力。

为进一步检验模型性能, 本文选取 RetinaNet、SSD、YOLOv3、YOLOv5s、Faster R-CNN、Cascade R-CNN 和本文提出的 LFRD 共 7 种模型在 TT100K 数据集上进行性能分析, 实验结果如表 4 所示, 其中前 4 个模型是一阶段检测模型, Faster R-CNN、Cascade R-CNN 是两阶段检测模型, 这些模型都被应用于交通标志检测方法的研究中。

表 4 不同方法在 TT100K 数据集上的实验结果

Table 4 Experimental results among different methods on the TT100K dataset

%

方法	精确率	召回率	F1 值	AP	AP ₅₀	AP ₇₅
RetinaNet ^[7]	88.7	90.7	89.7	71.4	90.0	85.3
SSD ^[15]	67.9	97.8	80.1	63.6	90.3	63.6
YOLOv5s	67.4	95.2	78.9	72.5	94.5	—
YOLOv3 ^[16]	73.7	95.3	83.1	72.6	95.2	—
Faster R-CNN ^[9]	57.2	98.4	72.3	55.8	90.9	65.9
Cascade R-CNN ^[11]	75.2	97.8	85.0	59.0	90.6	71.8
LFRD	91.5	96.3	93.8	76.1	96.3	91.1

从表 4 可以看出, 本文提出的 LFRD 的 AP、AP₅₀ 和 F1 值分别取得 76.1%、96.3% 和 93.8%, 均优于其他方法。与一般检测器 RetinaNet、SSD、YOLOv5s、YOLOv3 相比, LFRD 的 AP₅₀ 评价指标分别提高约 6.3、6.0、1.8 和 1.1 个百分点。与 Faster R-CNN 和 Cascade R-CNN 相比, LFRD 在 AP₅₀ 上分别提高 5.4 和 5.7 个百分点。相比 SSD、Faster R-CNN、Cascade R-CNN, 虽然 LFRD 的召回率略低, 但是精确率提高了约 10 个百分点。因此, LFRD 能有效降低误检率, 从而提高综合检测性能。

为进一步验证该方法的性能, 本文将在 TT100K

数据集上检测的结果映射至原图, 消除因窗口剪裁所导致部分错误的交通标志被子图边界截断, 从而容易得到对不完整交通标志检测的结果。现有交通标志检测方法在 TT100K 数据集上的实验结果对比如表 5 所示。

表 5 现有交通标志检测方法在 TT100K 数据集上的实验结果

Table 5 Experimental results of existing traffic sign detection methods on TT100K dataset

方法	输入尺寸/像素	主干网络	AP/%	AP ₅₀ /%	AP ₇₅ /%
文献[4]方法	512×512	DarkNet 53	—	96.5	—
文献[19]方法	512×512	DenseNet	—	92.8	—
SignHRNet ^[32]	512×512	HRNet-DA	69.5	93.8	82.7
文献[17]方法	640×640	DarkNet 53	69.0	95.1	—
TSingNet ^[5]	1 024×1 024	ResNet 50	67.3	93.3	81.5
Dense-RefineDet ^[33]	1 024×1 024	VGG-16	62.3	91.2	78.6
SignHRNet ^[32]	1 024×1 024	HRNet-DA	73.7	97.1	86.0
MF-SSD ^[34]	1 024×1 024	VGG-16	62.4	91.2	78.8
SegU-Net ^[35]	1 024×1 024	SegU-Net	65.1	92.5	80.4
LFRD	512×512	ResNet 50	75.4	97.0	89.5

从表 5 可以看出, 本文提出的 LFRD 在 AP 和 AP₇₅ 上取得最高结果分别为 75.4% 和 89.5%, 与输入尺寸 1 024×1 024 像素的 SignHRNet 相比 AP₅₀ 降低 0.1 个百分点, 可能是因为输入尺寸较大减少了因剪裁产生的不完整目标。AP 和 AP₇₅ 对预测结果和标签之间的 IoU 要求更高, 本文方法在 AP 和 AP₇₅ 取得更优的检测效果, 表明 LFRD 在交通标志检测任务中检测更精确的边界盒。

3.4 消融实验

为验证分层聚类锚框的有效性以及为每层选择合适的锚框数量, 本文设计 2 种参数不同的方案, 分别在 TT100K 数据集上进行实验, 实验结果如表 6 所示。消融实验都是基于 RetinaNet 作为检测框架, 更换了模型中的 anchor 机制, 在使用分层聚类锚框时仅保留了 P₃~P₆ 检测层。RetinaNet 使用文献[7]中描述的平移不变锚框, Kmeans₃、Kmeans₆ 使用本文提出的分层聚类锚框且每层锚框数分别为 3 个和 6 个。

表 6 不同锚框策略的实验结果对比

Table 6 Comparison of experimental results among different anchor box strategies

方法	锚框数/个	精确率/%	召回率/%	AP/%	AP ₅₀ /%	AP ₇₅ /%
RetinaNet	9	88.7	90.7	71.4	90.0	85.3
Kmeans ₃	3	81.7	96.1	75.7	95.5	90.5
Kmeans ₆	6	77.5	96.1	75.6	95.5	90.4

从表6可以看出,RetinaNet虽然精确率更高,但是受尺度变化的影响,其召回率较低,存在较多漏检问题。使用分层聚类锚框的Kmeans₃和Kmeans₆方法都能更好应对尺度变化问题并有效提高召回率,其综合性能AP、AP₅₀、AP₇₅更优。虽然Kmeans₃和Kmeans₆方法的精确率较低,但是分层聚类锚框主要是针对交通标志的尺度变化降低漏检。

Kmeans₆的参数量更多但是效果提升并不明显,Kmeans₃在精确率、AP以及AP₇₅的效果都略优于Kmeans₆。因此,本文选择Kmeans₃对平移不变锚框进行改进。

在确定锚框策略后,为验证其他模块对模型的有效性,本文基于Kmeans₃依次加入 l_{group} 、LRFPN、PM在TT100K数据集上进行实验,实验结果如表7所示。

表 7 消融实验结果

Table 7 Ablation experiment results

实验组号	l_{group}	LRFPN	PM	精确率/%	召回率/%	AP/%	AP ₅₀ /%	AP ₇₅ /%
1				81.7	96.1	75.7	95.5	90.5
2	√			84.1	96.4	75.2	95.9	90.4
3		√		88.1	96.2	75.9	95.8	91.0
4	√	√		89.8	96.8	76.1	96.3	91.1
5	√	√	√	91.5	96.7	76.1	96.3	91.1

从表7可以看出,实验2仅加入 l_{group} , l_{group} 通过指导模型学习相似类别之间的差异,与实验1相比在降低错误分类的同时精确率和召回率提高2.4和0.3个百分点。实验3仅加入LRFPN,LRFPN有效降低干扰特征产生的影响,利用WSS和FRM模块实现逐层细化并利用通道注意力优化特征,与实验1相比精确率和召回率提高6.4和0.1个百分点。

实验4加入 l_{group} 和LRFPN,与实验1相比 l_{group} 与LRFPN相结合的精确率和召回率提高8.1和0.7个百分点,AP、AP₅₀、AP₇₅分别提高到76.1%、96.3%、91.1%。实验5在实验3的基础上加入PM,PM模块是为了更高效地使用多尺度语义分割图,利用其监督检测结果。将PM模块加入到 l_{group} 和LRFPN中召回率减少了0.1个百分点,而精确率提高1.7个百分点。

LRFPN的检测和分割效果如图6所示,位于黑色区域将会受到FRM的特征细化以及PM模块的惩罚,降低相似物体的误检。




图 6 小目标的检测和分割结果

Fig.6 Detection and segmentation results for small targets

图7所示为本文以热力图的形式展示模块功能(彩色效果见《计算机工程》官网HTML版)。 P_3 、 P_4 分

别代表主干网络提取第3层和第4层特征所使用的卷积压缩模块的热力图,CE_{3,1}和CE_{3,2}分别代表细化第3层特征所使用FRM中2个模块的热力图。经多尺度特征融合后,同样将多尺度特征中的干扰特征汇聚在一起,由CE_{3,1}注意可能误检的部分,CE_{3,2}获取最终特征来提高检测精度。




图 7 不同模块的热力图

Fig.7 Heat maps among different modules

窗体剪裁会因窗体边缘和交通标志重叠导致交通标志不完整。本文将IoU大于50%的不完整交通标志设置为正样本并进行训练。但是数据增强中采用的随机缩放、图像平移、旋转等操作会模糊这些不完整交通标志的差异。不同区域的检测结果如图8所示,不完整的交通标志依旧保留外观特征容易被误检。



图8 不同区域的检测结果

Fig.8 Detection results for different regions

为减小不完整交通标志对检测效果的影响, 本文将检测结果映射回原图位置并利用非极大值抑制(Non-Maximum Suppression, NMS)消除重复项。NMS通过计算检测结果之间的交并比作为条件, 当2个结果重复区域大于阈值时, 则去除置信度低的结果。考虑到部分特征突出置信度更高从而压制整体目标的问题, 本文对NMS进行改进, 不再只考虑置信度, 而是将尺度大小也作为考量。改进NMS算法如算法1所示, 在原有的NMS基础上加入尺度判断, 当置信度都高于设定好的阈值时作为可信样本, 计算两者的面积比例并提高交并比的阈值, 以判断面积小的结果是否是突出特征部分。改进NMS性能测试结果如表8所示。

算法1 改进NMS算法

输入 $B = \{b_1, b_2, \dots, b_N\}$, $S = \{s_1, s_2, \dots, s_N\}$, $W = \{w_1, w_2, \dots, w_N\}$

输出 $M = \{m_1, m_2, \dots, m_K\}$

1. while $B \neq \text{empty}$ do //根据预测数值大小从序列中挑选//最大一位的下标。

2. $B' = \{b'_1, b'_2, \dots, b'_N\}$, $b'_i = b_i + w_i / b_i$ 是1张交通图像的窗//体预测结果, w_i 是对应的窗体参数, b'_i 表示利用窗体参数//将结果映射至原图。

3. $m \leftarrow \arg\max S$ //根据预测数值大小从序列中挑选最大//一位的下标。

4. $\text{flag} = 0$; $B \leftarrow B - b_m$ //将下标为m的预测结果从预测集//合B中删除。

5. for b_i in B do //遍历预测集合B中剩余结果。

6. $\text{iou} = \max\left(\frac{A \cap B}{A}, \frac{A \cap B}{B}\right)$ //算法中使用的交并比并非

//传统交并比而是交集所占比例最大值。

7. if $\frac{\text{area}(b_i)}{\text{area}(b_m)} \geq 1.5$ and $\text{iou}(b_m, b_i) > 0.7$ and $s_i > 0.5$

then $M \leftarrow b_i$, $B \leftarrow B - b_i$, $\text{flag} = 1$ //如果 b_i 置信度较高且面积远//大于 b_m 的同时, 两者交并比也大于一定阈值, 可以认定 b_m 是// b_i 的突出特征部分, 保留 b_i 而非 b_m 。

8. if $\text{iou}(M, b_i) \geq N_i$ then $B \leftarrow B - b_i$ //删除交并比大于阈//值 N_i 的预测结果。

9. end //for 循环结束。

10. if $\text{flag} = 0$ then $M \leftarrow b_m$ //在没有预测结果满足条件6//时, b_m 入选。

11. end //while 循环结束。

表8 改进NMS性能测试结果

Table 8 Test results of improved NMS performance %

方法	AP	AP ₅₀	AP ₇₅
NMS	75.1	96.9	89.1
改进NMS	75.4	97.0	89.5

从表8可以看出, 利用NMS将结果映射至原图位置来降低不完整交通标志对检测结果的影响, 将AP₅₀提高到96.9%, AP和AP₇₅因为数据调整相对于未映射至原图的检测结果有一定下降。改进NMS方法在NMS的基础上解决局部特征置信度大于全局的问题, 在AP、AP₅₀、AP₇₅上分别提高0.3、0.1和0.4个百分点。

4 结束语

针对现有交通标志检测方法在复杂场景下难以准确识别外观相似的交通标志以及对其他相似物体误检的问题, 本文设计一种高精度检测模型LFRD。为应对交通标志的尺度变化, 设计一种分层聚类的锚框机制来降低漏检。为降低外观相似交通标志分类错误, 提出分组损失来指导和学习相似类之间的细微差异, 还设计弱语义分割模块和特征细化模块, 利用主动学习方式降低对其他相似物体的误检。实验结果表明, 相较于主体框架RetinaNet, LFRD在采用压缩通道和分组卷积减少模型负担的同时, 精确率和召回率分别提高2.8和6.0个百分点。下一步将利用蒸馏机制训练轻量化主干网络, 并加入PAN优化多尺度特征融合, 在实现轻量化的同时提高模型性能。

参考文献

- [1] GREENHALGH J, MIRMEHDI M. Real-time detection and recognition of road traffic signs[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(4): 1498-1506.
- [2] FLEYEH H, DAVAMI E. Eigen-based traffic sign recognition[J]. IET Intelligent Transport Systems, 2011, 5(3): 190.
- [3] GONZALEZ Á, GARRIDO M Á, LLORCA D F, et al. Automatic traffic signs and panels inspection system using computer vision[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(2): 485-499.
- [4] YANG T T, TONG C. Real-time detection network for tiny traffic sign using multi-scale attention module[J]. Science China Technological Sciences, 2022, 65(2): 396-406.
- [5] LIU Y Y, PENG J Y, XUE J H, et al. TSingNet: scale-aware and context-rich feature learning for traffic sign detection and recognition in the wild[J]. Neurocomputing, 2021, 447: 10-22.
- [6] ZHU Z, LIANG D, ZHANG S H, et al. Traffic-sign detection and classification in the wild[C]//Proceedings of

- Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2016; 2110-2118.
- [7] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//Proceedings of IEEE International Conference on Computer Vision. Washington D. C. , USA; IEEE Press, 2017; 2999-3007.
- [8] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2018; 7132-7141.
- [9] 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.
- [10] DAI J F, LI Y, HE K M, et al. R-FCN: object detection via region-based fully convolutional networks[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York, USA; ACM Press, 2016; 379-387.
- [11] CAI Z W, VASCONCELOS N. Cascade R-CNN: delving into high quality object detection [C]//Proceedings of Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2018; 6154-6162.
- [12] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//Proceedings of International Conference on Computer Vision. Washington D. C. , USA; IEEE Press, 2017; 2980-2988.
- [13] LIU Z W, SHEN C, FAN X, et al. Scale-aware limited deformable convolutional neural networks for traffic sign detection and classification[J]. IET Intelligent Transport Systems, 2020, 14(12): 1712-1722.
- [14] WANG Z S, WANG J Q, LI Y L, et al. Traffic sign recognition with lightweight two-stage model in complex scenes[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(2): 1121-1131.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]//Proceedings of European Conference on Computer Vision. Berlin, Germany; Springer, 2016; 21-37.
- [16] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. [2022-10-25]. <https://arxiv.org/pdf/1804.02767.pdf>.
- [17] 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.
- [18] ZHANG S F, WANG Q Y, ZHU T, et al. Detection and classification of small traffic signs based on cascade network[J]. Chinese Journal of Electronics, 2021, 30(4): 719-726.
- [19] MIN W D, LIU R K, HE D J, et al. Traffic sign recognition based on semantic scene understanding and structural traffic sign location [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 15794-15807.
- [20] 曾雷鸣, 侯进, 陈子锐, 等. 基于弱语义分割的轻量化交通标志检测网络[J]. 计算机工程, 2022, 48(9): 269-276, 285. ZENG L M, HOU J, CHEN Z R, et al. Lightweight traffic sign detection network based on weak semantic segmentation[J]. Computer Engineering, 2022, 48(9): 269-276, 285. (in Chinese)
- [21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017; 936-944.
- [22] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]//Proceedings of Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2018; 8759-8768.
- [23] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//Proceedings of Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2016; 770-778.
- [24] 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 International Joint Conference on Neural Networks. Washington D. C. , USA; IEEE Press, 2014; 1-8.
- [25] VAN ET TEN A. You only look twice: rapid multi-scale object detection in satellite imagery[EB/OL]. [2021-08-01]. <https://arxiv.org/pdf/1805.09512.pdf>.
- [26] WEI J, WANG S H, HUANG Q M, et al. F3Net: fusion, feedback and focus for salient object detection[EB/OL]. [2022-10-25]. <https://arxiv.org/abs/1911.11445>.
- [27] ZHANG J M, ZHENG Z F, XIE X D, et al. ReYOLO: a traffic sign detector based on network reparameterization and features adaptive weighting[J]. Journal of Ambient Intelligence and Smart Environments, 2022, 14(4): 317-334.
- [28] REN K, HUANG L, FAN C Q, et al. Real-time traffic sign detection network using DS-DetNet and lite fusion FPN[J]. Journal of Real-Time Image Processing, 2021, 18(6): 2181-2191.
- [29] LIU F, QIAN Y R, LI H A, et al. CAFFNet: channel attention and feature fusion network for multi-target traffic sign detection [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2021, 35(7): 1-10.
- [30] WEI H Y, ZHANG Q Q, QIAN Y R, et al. MTSDet: multi-scale traffic sign detection with attention and path aggregation [J]. Applied Intelligence, 2023, 53(1): 238-250.
- [31] ZHANG Y L, LU Y, ZHU W Q, et al. Traffic sign detection based on multi-scale feature extraction and cascade feature fusion[J]. The Journal of Supercomputing, 2023, 79(2): 2137-2152.
- [32] YU Y T, JIANG T, LI Y Y, et al. SignHRNet: street-level traffic signs recognition with an attentive semi-anchoring guided high-resolution network [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 192: 142-160.
- [33] SUN C, AI Y B, WANG S, et al. Dense-RefineDet for traffic sign detection and classification[J]. Sensors, 2020, 20(22): 6570.
- [34] JIN Y M, FU Y S, WANG W Q, et al. Multi-feature fusion and enhancement single shot detector for traffic sign recognition[J]. IEEE Access, 2020, 8: 38931-38940.
- [35] KAMAL U, TONMOY T I, DAS S, et al. Automatic traffic sign detection and recognition using SegU-Net and a modified tversky loss function with L1-constraint[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(4): 1467-1479.