

CoCo-SEAM:融合颜色相关图与自集成多尺度 注意力的被遮挡交通标志检测算法*

蓝章礼¹ 文 鸿¹ 张 洪² 张 勇¹ 陈 希¹(1.重庆交通大学信息科学与工程学院 重庆 400074; 2.重庆交通大学省部共建山区桥梁及
隧道工程国家重点实验室 重庆 400074)

摘 要: 交通标志的自动检测对于提升自动驾驶车辆的环境感知鲁棒性至关重要。在实际环境中,交通标志常常受到遮挡,其检测面临背景环境复杂、目标尺度小以及标志信息不完整造成检测性能下降的问题。针对被遮挡交通标志在复杂背景下易与环境混淆的问题,提出一种基于颜色相关图的特征提取方法 C2f_color,充分利用交通标志具有鲜明、稳定的颜色特征,以增强其在复杂场景下的可区分性;针对交通标志在图像中占比较小和分辨率有限的问题,提出一种融合自集成多尺度注意力机制(SEAM)的特征增强模块 C2SEAM,通过多尺度特征提取增强遮挡交通标志的特征表征能力,以提升对小占比目标和低分辨率样本的检测精度;针对交通标志被遮挡后标志信息不完整的问题,提出采用上下文混合卷积(ContMix),通过融合更多上下文信息来补充缺失特征,以完善遮挡交通标志的表征。在 CCTSDB 公开数据集和自制复杂环境遮挡交通标志数据集(TSOCC)上的 mAP@0.5 相较于基准模型分别提升 8.4%和 3.5%, P 分别提升 0.9%和 6.2%。

关键词: 遮挡的交通标志;目标检测;颜色相关图;特征增强;ContMix 卷积

中图分类号: TN911.73;TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.2040

CoCo-SEAM: A traffic sign detection algorithm for occluded signs based on color correlation and self-ensembling multi-scale attention

Lan Zhangli¹ Wen Hong¹ Zhang Hong² Zhang Yong¹ Chen Xi¹

(1. School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China;

2. State Key laboratory of Mountain Bridge and Tunnel Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Automatic detection of traffic signs is crucial for improving the robustness of environmental perception in autonomous vehicles. In real-world scenarios, traffic signs are often occluded, resulting in issues such as complex background interference, small target scale and incomplete sign information, which degrade detection performance. To address the challenge of occluded traffic signs in complex backgrounds, we propose a feature extraction method C2f_color based on color correlogram, which leverages the prominent and stable color features of traffic signs to enhance their distinguishability in challenging scenes. For small-scale targets and low-resolution problems, we introduce a feature enhancement module C2SEAM that integrates a self-ensembling multi-scale attention mechanism (SEAM), which improves the model's ability to extract fine-grained features across multiple scales and enhances detection accuracy for small objects and low-resolution samples. Additionally, to handle missing sign information due to occlusion, we propose contextmixing convolution(ConMix), which dynamically fuses contextual information to compensate for missing features and improve the representation of occluded traffic signs. Experiments on the CCTSDB public dataset and our custom traffic sign dataset under occlusion and complex conditions (TSOCC) show that our method improves mAP@0.5 by 8.4% and 3.5%, respectively, while P increases by 0.9% and 6.2%, respectively, compared with the baseline model.

Keywords: occluded traffic signs; object detection; color correlation; feature enhancement; ContMix convolution

0 引 言

随着智能驾驶技术的广泛应用,环境感知系统对交通

标志的精准识别已成为保障行车安全的关键技术环节。但在现实道路场景中,交通标志易受枝叶遮蔽、车辆遮挡和异物覆盖,使得传统检测算法在特征提取与语义解析方面表

现出明显的局限性。感知失效可能引发自动驾驶系统决策延迟甚至误判,在交叉路口、匝道汇入等关键交通节点更显著增加了碰撞风险。因此,构建具有遮挡自适应的检测模型不仅可增强智能驾驶系统的环境冗余性,更能通过多模态数据融合与深度学习架构优化,实现遮挡区域的概率化推理与标志语义重建。当前研究多聚焦于改进你只需要看一次(you only look once, YOLO)系列算法,这类技术突破对于提升复杂场景下的系统鲁棒性具有重要工程价值,更为智能驾驶技术从实验室验证向大规模商业化落地提供了关键支撑。此外,在仪表与测量相关的工程场景中,视觉检测同样被广泛用于复杂户外环境下的缺陷识别与状态评估,刘传洋等^[1]对输电线路金具锈蚀缺陷的视觉检测研究进展进行了系统综述,为复杂环境下的鲁棒视觉感知提供了参考。

近年来,研究者们围绕交通标志检测问题开展了大量研究。在交通标志尺寸小且难以检测的场景中,Meng等^[2]提出基于改进YOLOv7^[3]的识别方法,通过SPPFCSPC模块强化小目标的特征提取,设计S-CARAFE上采样算子提升特征细节重组能力,并引入归一化Wasserstein距离(normalized Wasserstein distance, NWD)度量^[4]缓解小目标敏感性问题。Liang等^[5]提出改进的RT-DETRASL模型,通过逆残差模块轻量化主干网络,结合多尺度可变形注意力机制^[6]和S2小目标检测层优化特征学习,提升实时性与小目标检测精度。此外,Shen等^[7]设计C2f-faster-CGLU模块降低网络参数量,结合SPPFLSKA模块增强特征提取,融合小目标检测层与WISE-Inner-MPDIoU损失函数提升检测性能;王斌等^[8]则利用Backbone残差连接机制、I-PAFPN结构逆向优化、四级检测层扩展及WiIoU损失函数^[9]引入,有效改善小目标检测效果;宋京京等^[10]通过Conv-SPD模块替代跨步卷积下采样,增加小目标检测层,结合多尺度空间语义特征融合机制及MPDIoU损失函数,提升了交通标志小目标检测能力。然而,上述方法虽关注了小目标问题,却未充分考虑真实交通环境中复杂背景和遮挡问题。

在复杂背景干扰方面,王浩等^[11]提出融合压缩-激励网络(squeeze-and-excitation network, SENet)与ResNeXt结构的Detect_SR检测头,集成DySample动态上采样器,增设多尺度输出层,引入Shape-IoU损失函数及DKN-Attention注意力机制降低背景干扰;刘晶等^[12]则通过基于FreLU激活函数构建DBF/CBF卷积层强化Backbone和Neck模块特征提取,结合归一化通道注意力机制(normalized channel attention module, NCAM)增强Head模块特征表达,有效抑制复杂背景干扰。此外,许明等^[13]构建膨胀卷积的多分支特征提取模块,融合渐进特征金字塔结构优化SPPCSPC模块特征交互及下采样全局感知,提升复杂场景检测的鲁棒性;罗向龙等^[14]在主干网络中嵌入全维动态卷积与高效多尺度注意力(efficient multi-scale

attention, EMA)机制^[15],增强上下文感知能力;李嘉豪等^[16]则使用特征细化模块与通道注意力构建逐层细化特征金字塔,降低背景干扰问题;Han等^[17]通过EfficientVit主干网络提升复杂场景交通标志的全局特征感知能力。同时,栾添添等^[18]从颜色不变量与多尺度特征融合角度提升目标定位鲁棒性,为复杂光照与背景条件下的颜色先验建模提供了启示;俞林森等^[19]提出融合前景注意力的轻量级交通标志检测网络,在保证效率的同时增强对关键区域的关注能力。然而,上述方法多聚焦背景抑制,却忽视了交通标志可能被遮挡造成的语义信息缺失问题。

针对交通标志被遮挡问题,陈子昂等^[20]采用双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)替换路径聚合网络(path aggregation network, PANet)增强特征融合,利用卷积块注意力模块(convolutional block attention module, CBAM)^[21]提高遮挡交通标志的检测精度;蓝章礼等^[22]设计MobileNetv2改进的主干网络,配合动态权重上采样模块(dynamic-weighted upsampling module, DEUM)显著提高细粒度特征感知以提升遮挡情况下交通标志的检测精度;He等^[23]则通过CBAM机制强化形状与颜色感知,优化遮挡条件下检测性能;Wang等^[24]提出聚类注意力交通标志遮挡方法(cluster attention traffic-sign occlusion, CASO),基于点云构建倾斜锥体,以遮挡面积与体积比率进行评估;Gouda等^[25]提出基于密集点云数据的遮挡评估方法,构建道路数字孪生与传感器模拟系统。此外,陈丹等^[26]提出的新型遮挡目标分割模型在遮挡场景的特征建模与定位约束方面给出了有益探索,可为遮挡区域的结构推理与语义补全提供借鉴。然而,上述研究方法虽然提升了遮挡条件下的检测能力,但在同时面临交通标志尺寸小、背景复杂和遮挡严重的综合场景时,缺乏有效的整体性解决方案。

此外,针对遮挡问题,近年来国内外研究进一步引入了动态卷积(dynamic convolution)与变换器结构(Transformer)等具有上下文自适应特性的模型,以增强网络对被遮挡区域的结构推理能力。一类工作通过引入具有输入自适应特性的动态卷积核,根据局部上下文信息实时调整卷积权重,以提升网络在目标部分缺失情况下的特征表达能力;例如,在行人检测、车辆检测等任务中,动态卷积被用于加强未被遮挡区域对被遮挡部分的补偿,从而减缓遮挡带来的精度下降。另一类工作则借助Transformer的长程依赖建模优势,将图像中空间上相距较远的结构线索进行关联,通过全局注意力机制对被遮挡区域进行语义补全。需要指出的是,CASO方法^[21]主要面向交通标志的遮挡程度与可视性评估,通过构建基于点云的倾斜锥体模型并计算遮挡面积与体积比率实现遮挡分析,其目标并非提升2D图像检测网络的表征能力。相比之下,本文引入的上下文混合卷积(context mixing convolution, ContMix)是一种基于token相似性的上下文混合算子,具备类似动态

卷积的自适应特性,可在固定卷积核大小下动态融合局部与长程上下文信息,从而在特征层补偿遮挡导致的语义缺失。二者在研究目标与技术路线方面存在本质差异。

综合来看,现有基于动态卷积和 Transformer 的方法虽然在一般目标或三维点云场景中表现突出,但往往侧重于全局关系建模或动态权重生成,并未同时结合颜色先验、多尺度注意力与上下文混合机制,更缺乏面向复杂遮挡交通标志检测场景的一体化解决方案,这在真实道路环境中仍构成瓶颈。

综上所述,现有研究在小目标检测、复杂背景抑制及遮挡鲁棒性方面做出了重要贡献,但大多仅关注单一问题或两个问题的组合,在面对真实复杂场景下交通标志尺寸小、背景干扰强且严重遮挡3种挑战同时存在的条件下表现不足。因此,针对上述综合挑战,本文提出一种改进的交通标志检测算法。针对交通标志在复杂背景下易与环境混淆的问题,考虑到交通标志的颜色往往比较鲜艳,设计了一种使用颜色相关图来加强交通标志的颜色信息的特征提取模块。改进后的特征提取模块能够通过颜色信息,更多地关注到交通标志。针对交通标志在图像中占比较小和图像分辨率低的问题,在跨阶段部分空间注意力模块(cross stage partial spatial attention, C2PSA)多尺度特征模块中引入了自集成注意力机制(self-ensembling attention mechanism, SEAM)注意力机制的多尺度变体,改进后的 C2PSA 模块能够提高特征图的分辨率并增强网络的小目标检测能力。为了解决交通标志被遮挡后的难检测问题,使用 ContMix 卷积,改进原检测算法的颈部网络,改进后的颈部网络能够获得更多的上下文信息,从而增强对不完整交通标志的检测精度。

1 方法

1.1 颜色特征提取模块

在复杂道路场景中,被遮挡交通标志往往与周围环境在颜色上存在干扰,单纯依靠卷积特征容易导致目标与背景混淆。尤其是交通标志普遍具有颜色鲜明、搭配规律固定的特点,如果能够显式利用这种颜色与空间的共现规律,将有助于增强模型对遮挡目标的判别能力。基于此,本文引入颜色相关图(color correlogram)这一基于颜色空间分布的特征描述方法,其核心原理是通过量化颜色信息并建模颜色对在特定空间距离下的统计相关性,从而同时捕捉颜色分布及其空间结构特征。首先对图像的颜色空间进行离散化处理,将连续的 RGB 空间颜色值映射到有限的代表性颜色集合。具体地,采用聚类算法对 RGB 空间进行压缩,得到包含 N 个代表颜色的集合:

$$C = \{c_1, c_2, \dots, c_N\} \quad (1)$$

其中, N 表示聚类得到的颜色簇数, c_i 表示第 i 个代表性颜色。

在此基础上,对于集合中的每个颜色 c_i , 统计所有像素点中颜色为 c_i 的像素,并计算其在不同邻域距离 d 下,

周围像素颜色为 c_j 的条件概率。由此可得颜色相关矩阵 $\mathbf{\Gamma}_d \in \mathbf{R}^{N \times N}$:

$$\mathbf{\Gamma}_d(c_i, c_j) = P(\text{领域} = c_j \mid \text{中心} = c_i, d) \quad (2)$$

其中, $\mathbf{\Gamma}_d(c_i, c_j)$ 表示当中心像素为颜色 c_i 时,在距离 d 的邻域内出现颜色 c_j 的概率,矩阵 $\mathbf{\Gamma}_d$ 的行索引对应中心颜色 c_i , 列索引对应邻域颜色 c_j 。因此, $\mathbf{\Gamma}_d$ 是一个由所有颜色对条件概率构成的 $N \times N$ 概率矩阵。

当考虑多个不同的邻域距离 $d_1, d_2, \dots, d_K$ 时,便可得到一个三维特征张量:

$$\mathbf{\Gamma} \in \mathbf{R}^{N \times N \times K} \quad (3)$$

其中,前两个维度分别对应中心颜色集合和邻域颜色集合,即 $\mathbf{\Gamma}(:, :, k)$ 表示在第 k 个距离尺度 d_k 下的颜色相关矩阵;而单个元素 $\mathbf{\Gamma}(i, j, k)$ 则表示当中心像素颜色为第 i 个颜色 c_i 时,其在距离 d_k 的邻域内出现第 j 个颜色 c_j 的条件概率。换言之, $\mathbf{\Gamma}$ 本质上是一个条件概率张量,用于描述颜色对在不同空间尺度下的共现分布。

这一统计过程通过遍历图像中所有颜色对的共现频率,并归一化处理每个颜色对的空间关联强度,使得颜色相关图不仅保留了颜色直方图的全局统计特性,还通过引入像素邻域的局部空间约束,克服了传统颜色直方图完全忽略颜色空间分布的缺陷。颜色相关图可能因颜色空间排布差异而不同,从而更精准地反映图像内容的相似性,也能使得需要被检测到的目标从复杂的背景中分离出来。颜色相关图的核心在于计算不同颜色对在空间邻域下的共现概率,其基本计算方式如式(4)所示。

$$\mathbf{\Gamma}_d(c_i, c_j) = \frac{\sum_{p_1 \in I_{c_i}} \sum_{p_2 \in N_d(p_1)} \delta(\text{color}(p_2) = c_j)}{\sum_{p_1 \in I_{c_i}} |N_d(p_1)|} \quad (4)$$

其中, I_{c_i} 为图像中所有颜色为 c_i 的像素集合, p_1 表示该集合中的某一中心像素; $N_d(p_1)$ 表示像素 p_1 在图像边界内、距离为 d 的邻域像素集合, p_2 为其中的某一邻域像素; $\delta(\cdot)$ 为示性函数,当条件满足时值为 1, 否则为 0。

颜色相关图可通过颜色掩膜膨胀和局部卷积操作实现,并转换为多通道卷积特征图。作为辅助任务的特征提取模块,本文将生成的颜色特征图使用残差连接的方式增强主干网络的特征提取能力。在原网络中的特征提取组件(C3K2)拥有强大的特征提取能力,对局部特征的提取能力有着优异效果,但是 C3K2 对全局特征的利用率偏低,其公式如式(5)所示。

$$\text{C3K2}(\mathbf{x}) = \text{Concat}(\mathbf{x}_1, \text{ConvBlock}(\mathbf{x}_2)) \quad (5)$$

该模块首先将输入特征图 $\mathbf{x}$ 分割成两部分 $\mathbf{x}_1$ 以及 $\mathbf{x}_2$, 然后 $\mathbf{x}_2$ 通过一系列 3×3 卷积层进行处理,形成卷积块 $\text{ConvBlock}(\mathbf{x}_2)$ 。最后,将 $\mathbf{x}_1$ 和 $\text{ConvBlock}(\mathbf{x}_2)$ 在通道维度上拼接,得到输出特征图。

为了加强全局特征的利用并减轻复杂背景的影响,将颜色相关图与深度神经网络相结合,本文首先选择了 RGB

颜色空间并进行颜色量化;其次对于每种颜色,计算在固定距离下,相同颜色或其他颜色的像素出现的概率;然后将计算出的颜色相关图矩阵展平成一维向量。将颜色相关图特征向量输入全连接层,得到相应形状的张量,然后通过复制将其扩展为原特征图形状大小的张量。最后再使用残差链接的方式,改进到 C3K2 特征提取模块中去,其公式如式(6)所示,其中 $\text{Color_feature}(\mathbf{x})$ 是生成的颜色特征图。其结构如图 1 所示。

$$\text{C2f_color}(\mathbf{x}) = \text{Color_feature}(\mathbf{x}) + \text{Concat}(\mathbf{x}_1, \text{ConvBlock}(\mathbf{x}_2)) \quad (6)$$




图 1 C2f_color 结构

Fig. 1 C2f_color module architecture

在实现上,记主干网络某一层的卷积特征为 $\mathbf{F} \in \mathbf{R}^{H \times W \times C}$, 其中 H, W 为特征图空间尺寸, C 为通道数;对输入图像计算得到的颜色相关张量 $\mathbf{g}$ 先经展平与全连接层映射为通道注意力向量 $\mathbf{a} \in \mathbf{R}^C$:

$$\mathbf{a} = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 \text{vec}(\mathbf{g}))) \quad (7)$$

其中, $\mathbf{W}_1$ 和 $\mathbf{W}_2$ 为可学习仿射变换, $\delta(\cdot)$ 表示非线性激活函数, $\sigma(\cdot)$ 为 Sigmoid 函数。随后,将向量 $\mathbf{a}$ 通过广播扩展到与 $\mathbf{F}$ 相同的空间尺寸,得到颜色引导的调制特征为:

$$\mathbf{F}_{\text{color}}(h, w, c) = \mathbf{a}_c \cdot \mathbf{F}(h, w, c) \quad (8)$$

最终输出特征采用残差形式与原特征相加:

$$\mathbf{F}_{\text{new}} = \mathbf{F} + \gamma \mathbf{F}_{\text{color}} \quad (9)$$

其中, γ 为可学习的平衡系数。可以看出,颜色相关图在本质上相当于为每个通道引入了一个由全局颜色共现关系驱动的权重,从而增强与交通标志典型颜色分布一致的特征通道,抑制背景区域主导的通道激活,使类内特征更加紧凑、类间特征更加分离。

通过颜色相关图的原理可以提取图像的全局颜色信息,并生成颜色特征图。结合残差连接, C2f_color 模块能够同时利用全局与局部特征,使网络在复杂背景下更准确地提取交通标志信息,从而提升检测精度。交通标志本身具有鲜明且稳定的颜色属性,引入颜色相关图能突出这一特征,帮助网络更好地建模全局信息。

可视化结果如图 2 所示。对比引入 C2f_color 模块前后的特征响应可以发现,在未使用颜色相关图时,背景区域的高响应区域较多,且与交通标志区域存在明显重叠,加入 C2f_color 模块后,高响应区域显著集中于标志红圈,复杂背景区域的响应得到抑制,进一步验证了颜色先验对复杂背景下特征判别性的增强作用。

1.2 基于多尺度注意力的特征增强模块

在实际交通场景中,交通标志往往在图像中仅占较小




图 2 颜色相关图融合前后特征响应对比

Fig. 2 Feature response comparison before and after color correlogram integration

区域,且部分样本受拍摄距离或清晰度影响分辨率有限,导致模型难以捕捉完整的细粒度特征。常规注意力机制虽然能够在一定程度上提升特征表征,但在处理这类小占比或低分辨率目标时,其关注范围可能不足,甚至会受到噪声或偏差的干扰。为此,本文在 C2PSA 模块中引入 SEAM^[27]。该机制通过并行或堆叠的注意力模块生成多样化的关注模式,并利用自适应融合策略动态聚合各分支输出,从而抑制单一注意力可能引入的偏差。与此同时,SEAM 还引入自洽性约束,使不同注意力分支在训练过程中协同优化,最终提升模型对关键特征的捕获能力,并在小目标与低分辨率场景下显著改善检测精度。

该注意力机制由图 3 所示的通道与空间混合模块(channel and spatial mixing module, CSMM)采用残差结构实现。该单元通过并行部署 3 个具有不同感受野(patch-6、patch-7、patch-8)的深度可分离卷积分支,在有效建模跨通道特征显著性并控制参数规模的同时,针对其未能显式捕捉通道间交互关系的局限性,通过点状卷积(1×1 卷积)对多尺度深度可分离卷积输出进行特征重组,实现通道间信息的非线性耦合。这种多尺度特征融合策略在维持计算效率的前提下,显著增强了特征表征的鲁棒性。为强化通道间关联性,采用两级全连接网络构建层级特征交互,通过自适应权重分配机制建立跨通道全局依赖关系。SEAM 注意力机制能够使用多尺度特征提取的方式,加强在低分辨率场景时,对小目标的检测精度。

通过 SEAM 注意力机制的原理进一步优化原检测网络的 C2PSA 模块,得到新的特征增强模块 C2SEAM,本文的优化方案能够使得该模块能够在更多尺度下提取到更多的特征,增强对小尺度目标的注意力聚焦。其结构如图 4 所示。

在自集成多尺度注意力块(self-ensembling multi-scale attention block, SEAMBlock)的设计中,采用了 4 个并行卷积分支,其卷积核大小设置为 $\{3, 5, 7, 9\}$ 。这种配置主要基于以下考虑:1)奇数大小的卷积核能够以中心像素为对齐点进行采样,避免偶数核带来的位移偏差;2)小卷积核($3 \times 3, 5 \times 5$)有利于捕获交通标志的边缘与纹理等细粒度信息,而较大卷积核($7 \times 7, 9 \times 9$)能够提供更丰富的局部上下文,




图 3 SEAM 注意力机制架构

Fig. 3 SEAM attention mechanism architecture




图 4 C2SEAM 注意力机制架构

Fig. 4 C2SEAM attention mechanism architecture

对被遮挡或低分辨率目标具有更强的特征补偿能力。该组

合基本覆盖了交通标志在特征图上从局部细节到整体轮廓的典型像素跨度,在表达能力与计算开销之间取得了较好的平衡。

此外,本文未在 SEAMBlock 中引入更大尺度的卷积分支(如 11×11 及以上),原因在于更大卷积核将显著增加计算成本,同时会造成与现有分支的感受野冗余,并且本框架中的长程上下文依赖已由后续的 ContMix 卷积模块显式建模,在 SEAMBlock 内扩大卷积核并不会带来额外收益。需要说明的是,SEAM 注意力机制中的其他结构性超参数(如 CSMM 模块中各分支的 patch 大小等)均沿用原始 SEAM 方法^[23]的默认设置,以保持对比的公平性并提高方法的可复现性。因此,将卷积核大小固定为 $\{3,5,7,9\}$ 、分支数设置为 4,不仅能够兼顾多尺度表征能力与计算效率,也便于后续研究在相同配置下直接复现本文方法。

融合了 SEAM 注意力机制的 C2PSA 模块是一种更高效的注意力机制,其在小目标特征的提取上的表现异常优异,SEAMBlock 模块通过引入不同大小的卷积核来提取多尺度的空间信息,其次结合 SEAM 注意力机制对不同尺度的特征信息再次使用不同感受野的特征提取方法,对交通标志的特征进行进一步丰富,加强在低分辨率的条件下,对小目标交通标志的检测精度。

1.3 ContMix 卷积

在遮挡场景下,交通标志往往存在信息缺失,仅依赖局部可见区域容易导致检测不完整或误判。例如,当标志数字或关键边缘被树叶、杆件部分遮挡时,局部特征已经不足以支撑精确分类和定位。为解决这一问题,网络需要能够整合更广域的上下文信息,以利用标志周围的红圈、白底等语义线索进行补偿。基于这一动机,本文引入 ContMix^[28],其结构如图 5 所示。




图 5 ContMix 卷积结构

Fig. 5 ContMix convolution structure

作为一种动态感知算子,通过区域中心划分策略建立特征图的空间上下文关联。其核心机制是基于可学习的空间亲和力系数动态生成自适应卷积核,其中大尺寸核权重用于捕获跨区域的全局依赖,小尺寸核参数则保留局部细节敏感性,从而在统一框架下实现全局与局部特征的协同建模。该算子通过参数化的全局-局部特征耦合方式,有

效平衡了感受野扩展与细节保留之间的矛盾。ContMix 能够被嵌入至检测框架的颈部网络,通过构建具有空间感知能力的动态特征融合模块,从而显著增强遮挡场景下交通标志的检测鲁棒性并提升检测精度。

ContMix 卷积的计算过程可分为 3 个步骤。首先,将输入特征图 $\mathbf{X}$ 通过两个 1×1 卷积和重塑、池化操作,分别

得到投影后的令牌特征 $\mathbf{X}_i \in \mathbf{R}^{N \times d}$, 以及区域中心上下文 $\mathbf{C} \in \mathbf{R}^{M \times d}$ 。其中, 令牌特征指将特征图展平后得到的每个空间位置的特征向量, $N = H \times W$ 表示令牌数(即展平后的空间位置数), d 为通道维度; 区域中心上下文则是通过自适应池化得到的 M 个代表性特征向量, 用于概括不同区域的上下文信息。

接着, 计算令牌与区域中心之间的相似度关系。通过矩阵乘积可得亲和矩阵:

$$\mathbf{A} = \mathbf{X}_i \mathbf{C}^T \in \mathbf{R}^{N \times M} \quad (10)$$

其中, 矩阵 $\mathbf{A}$ 的第 i 行记作 $\mathbf{A}_{i,:}$, 表示第 i 个令牌与所有 M 个区域中心的相似度向量。换言之, $\mathbf{A}_{i,j}$ 表示第 i 个令牌与第 j 个区域中心的相似度值。

随后, 引入可学习的线性投影矩阵 $\mathbf{W}$, 将每一行 $\mathbf{A}_{i,:}$ 投影到卷积核参数空间, 并经 softmax 归一化, 得到随位置动态变化的卷积核权重:

$$\mathbf{K}_i = \text{softmax}(\mathbf{A}_{i,:} \mathbf{W}) \in \mathbf{R}^{G \times K \times K} \quad (11)$$

其中, $\mathbf{K}_i$ 表示在位置 i 处生成的动态卷积核, G 为分组数, K 为卷积核大小。

最后, 在每个空间位置按组应用对应的动态核, 得到输出特征:

$$\mathbf{y}_i = \sum_{g=1}^G \sum_{\delta \in \Omega_g} \mathbf{K}_{i,g}(\delta) \cdot \mathbf{x}_{i+\delta,g} \quad (12)$$

其中, Ω_g 表示第 g 组对应的卷积核采样位移集合(例如 3×3 卷积对应 9 个采样点), $\mathbf{x}_{i+\delta,g}$ 为输入特征在位置 $i+\delta$ 、第 g 组的特征值, $\mathbf{K}_{i,g}(\delta)$ 为相应的卷积核权重。实现中将 G 个组划分为两类: 半数组使用大卷积核以建模跨区域的全局依赖, 半数组使用小卷积核以保持局部细节, 从而在统一框架下实现全局与局部特征的协同建模。

ContMix 卷积能在固定核大小下有效捕捉遮挡交通标志的距离依赖, 同时保留局部结构特征, 从而显著提升

有效感受野和特征融合与提取质量。

1.4 CoCo-SEAM 网络整体结构

YOLO 系列作为目标检测的代表性单阶段算法, 因其速度快、精度高而被广泛应用于交通标志检测任务。为了确定合适的基准网络, 本文首先对多种主流检测模型进行了对比实验, 结果表明 YOLO11 在精度与速度上均取得较优的综合表现。基于这一实验结果, 本文选择 YOLO11 作为基础框架, 并在其结构上引入针对性改进, 以适应被遮挡交通标志的检测需求。具体而言, 针对被遮挡的交通标志在背景复杂情况下易与环境混淆的问题, 本文提出一种基于颜色相关图的特征提取方法, 使用颜色特征提取模块 C2f_color 改进 YOLO11 的骨干网络, 使得骨干网络充分利用颜色这一基本特征, 有效减轻背景环境的影响, 增强了被遮挡交通标志的颜色特征, 使得网络能够在全局上更加关注到交通标志; 针对交通标志在图像中尺度小和图像分辨率低的问题, 普通的注意力机制在细粒度特征提取上存在不足, 本文使用 SEAM 注意力机制改进了原网络的 C2PSA 模块, 提出了一种融合 SEAM 注意力机制的特征增强模块 C2SEAM, 使得网络能够从更丰富的尺度去提取到交通标志的特征, 以避免低分辨率的影响, 且加强了对小目标特征的提取; 最后, 针对 YOLO11 颈部网络在检测遮挡目标时, 存在着上下文信息利用不足的问题, 为增强上下文信息的利用, 本文使用 ContMix 卷积改进 YOLO11 的颈部网络, 取代了原本的 CBS 卷积, 颈部网络中的 C3K2 内部的 CBS 同样使用了 ContMix 卷积进行优化, 改进后的颈部网络利用了丰富的上下文信息有效提升了对遮挡交通标志的检测。改进后的 YOLO11 网络架构如图 6 所示。

1.5 算法流程描述

基于 CoCo-SEAM 的遮挡交通标志检测训练流程如算法 1 所示。




图 6 基于 YOLO11 改进的检测网络架构

Fig. 6 Detection network architecture based on improved YOLO11

算法1 基于 CoCo-SEAM 的遮挡交通标志检测训练流程

输入:训练数据集 $D = \{(\mathbf{I}_i, \mathbf{Y}_i)\}_{i=1}^N$, 其中 $\mathbf{I}_i$ 为输入图像, $\mathbf{Y}_i$ 为对应标注

输出:训练好的模型参数 θ

1. 初始化网络参数 θ
2. for 每个训练样本 $(\mathbf{I}_i, \mathbf{Y}_i)$ do
3. //颜色相关图计算
4. 计算输入图像 $\mathbf{I}_i$ 的颜色相关张量 ϕ_i
5. //Backbone+C2f_color 特征提取
6. 将 $\mathbf{I}_i$ 输入改进 YOLO11 的 Backbone,依次经过 CBS 与 C3K2 模块提取多尺度特征 $\{\mathbf{F}_i^{(s)}\}$ (s 表示不同尺度)
7. 将 C3K2 替换为 C2f_color, ϕ_i 融合到中间特征中,得到颜色增强后的 Backbone 特征 $\{\tilde{\mathbf{F}}_i^{(s)}\}$, 同时保留浅层 Detail 分支特征用于后续融合
8. //C2SEAM 多尺度注意力增强
9. 将 $\{\tilde{\mathbf{F}}_i^{(s)}\}$ 送入 C2SEAM 模块,在其中的 SEAMBlock 中采用卷积核大小为 $\{3,5,7,9\}$ 的 4 个并行分支计算多尺度注意力,并通过自适应融合得到注意力增强特征 $\{\mathbf{G}_i^{(s)}\}$
10. //Neck+ContMix 上下文混合与特征金字塔融合
11. 将 $\{\mathbf{G}_i^{(s)}\}$ 及浅层 Detail 特征输入 Neck,通过下采样、上采样和 Concat 操作构建特征金字塔,在横向与纵向连接处采用 ContMix 卷积替换原有 CBS,对多尺度特征进行上下文混合,得到用于三尺度检测头的特征 $\{\mathbf{P}_i^{(s)}\}$
12. //检测头与损失计算
13. 将 $\{\mathbf{P}_i^{(s)}\}$ 输入 3 个尺度的检测头,获得预测结果 $\hat{\mathbf{Y}}_i$, 并根据 $\hat{\mathbf{Y}}_i$ 与标注 $\mathbf{Y}_i$ 计算分类损失、边界框回归损失和 IoU 损失,得到总损失 L_i
14. 使用 SGD 优化器根据 $\nabla_{\theta} L_i$ 更新模型参数 θ
15. end for
16. 返回训练好的模型参数 θ

2 实验结果与分析

2.1 数据集

目前国内交通标志检测领域常用的公开数据集主要包括 TT100K 和 CCTSDB。TT100K 数据集包含约十万张带有交通标志实例的图像,类别种类丰富,但不同类别间的样本数量差异较大,存在分布不均衡问题;CCTSDB 数据集则收录了约 1.8 万张交通场景图像,涵盖警告、禁止和指示 3 类主要标志类型。这两个数据集均包含部分在雨天、雾天等复杂气象条件下采集的样本,为算法的鲁棒性验证提供了较好的环境多样性。

为更好地满足遮挡交通标志检测的研究需求,本研究首先从上述两个公开数据集中选取部分含有自然状态下交通标志遮挡现象的图像,同时结合本实验室新采集的被遮挡交通标志图像,另外,为避免数据分布不均衡从而影响模型的泛化性能,进一步对数据集进行了增强处理并精心筛选,仅保留标志实例数超过 150 个的类别,最终命名为复杂环境遮挡交通标志数据集 (traffic sign dataset under occlusion and complex conditions, TSOCC)。本研究自建的遮挡交通标志数据集共包含 4 016 幅图像,覆盖 16 种常见交通标志类别,共标注 9 638 个交通标志实例。

交通标志类别如图 7 所示。考虑到原始图像中背景区域较大,不利于直观观察被遮挡标志的外观特征,本文对图像中的交通标志区域进行了独立裁剪,以便更清晰地展示样本特征,其部分示例如图 8 所示。



图7 交通标志类别

Fig.7 Traffic sign categories

为量化遮挡情况,本文以单个交通标志实例为统计单位,定义遮挡比例 r 为实例中被遮挡区域面积与标志整体面积之比。根据 r 的取值,将样本划分为 4 类:无遮挡 ($r=0$);轻微遮挡 ($0 < r < 0.2$);中等遮挡 ($0.2 \leq r < 0.5$);严重遮挡 ($r \geq 0.5$)。统计结果表明,在 TSOCC 数据集中,无遮



图 8 数据集样本

Fig. 8 Dataset samples

挡样本约占 15%，轻微遮挡样本约占 26%，中等遮挡样本约占 37%，严重遮挡样本约占 22%，其中中重度遮挡样本占比较高，能够更充分地考察检测算法在遮挡场景下的鲁棒性，具体结果如表 1 所示。

表 1 TSOCC 数据集中不同遮挡等级的样本统计

Table 1 Occlusion-level statistics of the TSOCC dataset

遮挡等级	样本数量	占比/%	场景
无遮挡	1 446	15	清晰无遮挡标志
轻微遮挡	2 506	26	轻微叶片遮挡
中等遮挡	3 566	37	车辆、立杆、树枝遮挡
严重遮挡	2 120	22	树冠、建筑物遮挡

此外，从遮挡来源来看，TSOCC 数据集中主要包含树枝树叶覆盖、道路设施遮挡、行驶车辆遮挡、广告牌及建筑物遮挡等多种典型场景。相较于公开的 CCTSDB 数据集，其遮挡样本数量较少，而复杂气象与光照条件更为丰富。因此，本文在对比实验中分别在 TSOSC 与 CCTSDB 上进行评估，前者侧重验证方法在遮挡场景下的检测能力，后者则侧重检验算法在复杂天气及光照变化条件下的泛化表现。

2.2 实验环境

本文实验在操作系统 Ubuntu 22.04 下进行，GPU 为 NVIDIA RTX 3090，内存为 24 GB，深度学习框架为 PyTorch 2.0.1，软件编程环境为 Python 3.9.19，CUDA 11.7。

实验超参数设置如下：训练轮数(epochs)为 300 轮，批量(batchsize)大小为 16，优化器(optimizer)为 SGD，初始学习率(learning rate)为 0.01，动量(momentum)为 0.937。

2.3 评价指标

为了全面评估模型在交通标志检测任务中的性能，本

文选取准确率(precision, P)、召回率(recall, R)、平均精度均值(mean average precision, mAP)、F1 值以及参数量(parameters, Params)作为主要评价指标。其中，Params 用于衡量模型的空间复杂度，其数值越大表示模型结构越复杂。此外，为验证模型在自动驾驶场景中的实时性表现，本文采用帧率(frames per second, FPS)作为速度指标。通常，检测算法需在 30 fps 以上才能满足车辆实时感知的需求。

2.4 消融实验

为了验证本文提出的各个改进模块的有效性，本文在自制的 TSOCC 数据集上进行了一系列消融实验，评估每个模块对模型性能的具体影响。实验结果如表 2 所示。

C2f_color 模块通过增强颜色特征提取，改善了模型在复杂背景中的表现。引入 C2f_color 模块后，mAP@0.5 从 74.8%提升至 75.3%，P 从 85.4%提升至 87.6%。该模块有助于提高在背景复杂或遮挡情况下交通标志的识别精度。

C2SEAM 模块通过多尺度自集成注意力机制，增强了模型对小目标和低分辨率目标的检测能力。引入 C2SEAM 模块后，mAP@0.5 从 74.8%提升至 75.9%，P 从 85.4%提升至 86.3%，R 从 69.3%提升至 70.3%。该模块有效提升了小目标和低分辨率场景下的检测性能。

ContMix 模块通过增强上下文信息的融合，提升了模型在遮挡条件下的鲁棒性。引入 ContMix 模块后，mAP@0.5 从 74.8%提升至 76.2%，P 从 85.4%提升至 88.1%，R 从 69.3%提升至 70.5%。该模块帮助模型更好地理解遮挡目标的空

间关系，从而提升了对遮挡交通标志的检测能力。与基准模型相比，每个模块的引入均有效提升了模型的检测性能。当 C2f_color、C2SEAM 和 ContMix 三个模块同时引入时，模型的性能达到最佳，mAP@0.5 提升至 78.3%，P 从 85.4%提升至 91.6%，R 从 69.3%提升至 72.1%。这一结果表明，3 个模块在特征提取、注意力机制和上下文信息融合方面具有协同作用，显著提升了模型在遮挡和复杂场景中的整体检测能力。

2.5 自制 TSOCC 数据集对比实验

评估模型在遮挡场景下对交通标志的识别能力，本研究基于自建的遮挡交通标志数据集开展模型性能对比实验，各实验组采用统一的参数设置以确保结果具有可比性，实验结果如表 3 和图 9 所示。

2.6 公开 CCTSDB 数据集对比实验

为检验模型在实际交通环境中的鲁棒性，本文选取公开的 CCTSDB 数据集进行对比实验。在实验过程中，所有模型均采用统一的训练与推理参数设置，以保证结果的可比性，结果如表 4 与图 10 所示。该数据集包含多种复杂气象与光照条件，如雨天、雾天、雪天及夜间场景，但遮挡样本数量相对较少；相比之下，自建遮挡数据集主要聚焦于遮挡因素而不涉及复杂天气。因此，在 CCTSDB 上模型整

表 2 消融实验

Table 2 Ablation experiments

(%)

Baseline	C2f_color	C2SEAM	ContMix	P	R	$F1$	mAP@0.5
✓	×	×	×	85.4	69.3	76.5	74.8
✓	✓	×	×	87.6	69.4	77.4	75.3
✓	×	✓	×	86.3	70.3	77.5	75.9
✓	×	×	✓	88.1	70.5	78.3	76.2
✓	✓	✓	×	91.9	71.4	80.4	78.1
✓	✓	×	✓	90.8	71.8	80.2	77.8
✓	×	✓	✓	90.4	71.3	79.7	77.5
✓	✓	✓	✓	91.6	72.1	80.7	78.3

表 3 自制 TSOCC 数据集各算法对比实验

Table 3 Comparison of algorithms on the custom TSOCC dataset

算法	Params/($\times 10^6$)	P /%	R /%	$F1$ /%	mAP@0.5/%	FPS
YOLOv5s	9.1	82.7	69.4	75.5	72.9	95.6
YOLOv7-Tiny	8.3	62.1	56.3	59.1	48.1	91.2
YOLOv8s	9.7	70.6	60.2	65.0	59.7	76.3
YOLOv9s	9.9	81.4	66.4	73.1	70.3	72.5
YOLOv10s	9.6	83.6	68.3	75.2	72.6	84.7
YOLO11s	9.4	85.4	69.3	76.5	74.8	90.6
SSD ^[29]	24.3	63.7	16.1	25.7	16.5	48.2
RetinaNet ^[30]	35.6	84.5	41.5	55.6	56.4	33.8
Faster R-CNN ^[31]	41.0	81.7	52.1	63.6	53.6	28.3
BH-RT-DETR ^[32]	22.8	87.2	70.8	78.1	75.6	42.7
DTI-YOLO ^[33]	9.3	89.2	70.7	79.0	76.8	78.1
本文	9.5	91.6	72.1	80.7	78.3	86.9




图 9 不同算法在 TSOCC 数据集上的性能对比雷达图

Fig. 9 Radar chart of algorithm performance on the TSOCC dataset

体表现出 P 略低而 R 较高的特征,体现出模型在非遮挡、复杂环境下的更强检出能力。

表 4 公开 CCTSDB 数据集各算法对比实验

Table 4 Comparison of algorithms on the CCTSDB dataset

(%)

算法	P	R	$F1$	mAP@0.5
YOLOv5s	89.6	69.2	77.5	76.3
YOLOv8s	85.3	69.2	76.3	76.0
YOLOv9s	88.7	69.1	77.0	76.2
YOLOv10s	89.4	69.4	77.7	76.3
YOLO11s	89.9	70.1	78.3	76.5
SSD ^[29]	86.5	27.7	41.7	49.2
RetinaNet ^[30]	86.7	52.9	65.7	57.8
Faster R-CNN ^[31]	84.4	54.9	66.2	56.6
Libra R-CNN ^[34]	83.7	60.1	69.0	61.4
Dynamic R-CNN ^[35]	86.9	58.3	69.4	60.1
本文	90.8	77.6	83.8	84.9

2.7 可视化分析

在本文实验部分,进一步利用可视化结果直观地对比了不同检测模型在自制 TSOCC 数据集上的表现,如图 11




图 10 不同算法在 CCTSDB 数据集上的性能对比雷达图
Fig. 10 Radar chart of algorithm performance on the CCTSDB dataset

所示。图 11 中预测框上方的标注信息依次包含了类别编号、预测置信度以及目标框位置，不同类别的标志采用不同颜色区分。置信度反映了模型对该目标预测结果的可信程度，数值范围在 0~1，越接近 1 表明模型对该预测越有把握。




图 11 检查结果可视化

Fig. 11 Visualization of inspection results

从结果来看，大部分主流模型都能够识别出目标类别，但其预测置信度存在明显差异。例如在第 1 幅测试样本中，YOLOv7 与 SSD 的检测效果明显不足，未能成功识别目标；而 YOLO 系列模型大多能够给出正确类别预测，但置信度水平参差不齐，其中 YOLOv7、YOLOv8 等较弱模型在小目标或模糊场景下置信度偏低。相比之下，本文提出的方法在多组样本上均能保持较高的置信度水平，体现出对目标的更强鲁棒性和更可靠的检测性能。

2.8 误检漏检样本分析

在交通标志检测任务中，误检与漏检会直接影响模型的可靠性和实用性，也是检测算法难以避免的问题。本文对提出的算法进行了典型样本分析，如图 12 所示。在图 12(a)中，目标交通标志虽然存在，但由于其可见区域过于有限且细节模糊，几乎没有形成足够判别性的特征，再

加上训练集中类似样本分布较少,最终导致模型未能正确识别,出现漏检现象;在图12(b)中,部分交通标志类别外观相似,图12(c)中,加之关键区域被遮挡,模型将背景错误识别为目标,从而造成误检。



(a) 交通标志漏检
(a) Missed detection of traffic signs



(b) 交通标志误检
(b) False detection of traffic signs



(c) 相似交通标志
(c) Similar traffic signs

图12 检测失败样例

Fig. 12 Detection failure examples

总体来看,当交通标志的可见区域过小或特征细节不足以及类间相似度高且伴随遮挡的情况,更容易引发误检与漏检问题,后续仍需在提高模型对低质量目标的判别能力和增强细粒度类别区分方面进一步改进。

3 结 论

针对被遮挡交通标志检测中存在的背景干扰强、目标信息缺失及检测精度下降等问题,本文提出了一种融合颜色相关图与自集成多尺度注意力的检测算法(CoCo-SEAM)。该算法包括3项核心改进:基于C2f_color的特征提取模块,显式建模颜色空间分布关系,增强网络对交通标志颜色特征的感知能力;融合C2SEAM的特征增强模块,提高网络对小占比目标与低分辨率样本的细粒度特征提取能力;引入ContMix建模全局与局部空间依赖,补偿遮挡场景中的语义缺失。

在自制TSOCC数据集上,本文方法的mAP@0.5达到78.3%,较YOLO11s提升3.5%, P 和 R 分别提升

6.2%与2.8%,并保持86.9 fps的实时性能;在公开CCTSDB数据集上,mAP@0.5提升至84.9%,验证了算法在复杂交通环境下的鲁棒性与泛化能力。

未来工作将进一步扩充数据集规模,涵盖多种天气、光照与遮挡条件,并探索轻量化结构与多模态融合策略,以持续提升模型的检测精度与实时性,为自动驾驶系统中的交通标志识别提供更可靠的技术支持。

参考文献

- [1] 刘传洋,吴一全,刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报, 2024, 45(3): 286-305.
LIU CH Y, WU Y Q, LIU J J. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 286-305.
- [2] MENG B, SHI W D. Small traffic sign recognition method based on improved YOLOv7[J]. Scientific Reports, 2025, 15(1): 5482.
- [3] 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[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.
- [4] XU C, WANG J W, YANG W, et al. Detecting tiny objects in aerial images: A normalized Wasserstein distance and a new benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 79-93.
- [5] LIANG N L, LIU W S. Small target detection algorithm for traffic signs based on improved RT-DETR[J]. Engineering Letters, 2025, 33(1): 140-147.
- [6] ZHU X Z, SU W J, LU L W, et al. Deformable DETR: Deformable transformers for end-to-end object detection[C]//International Conference on Learning Representations, 2021.
- [7] SHEN Q, LI Y, ZHANG Y X, et al. CSW-YOLO: A traffic sign small target detection algorithm based on YOLOv8[J]. PLoS One, 2025, 20(3): e0315334.
- [8] 王斌,徐洪华,孙兜成,等. 基于YOLOv8算法改进的小目标交通标志检测[J]. 计算机应用, 2024, 44(S2): 274-279.
WANG B, XU H H, SUN D CH, et al. Improved small traffic sign detection based on YOLOv8 algorithm[J]. Journal of Computer Applications, 2024, 44(S2): 274-279.
- [9] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing

- mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [10] 宋京京,张振利.基于 YOLOv8n 的小目标交通标志检测算法[J].科学技术与工程, 2024, 24(36): 15548-15557.
SONG J J, ZHANG ZH L. Small-target traffic sign detection algorithm based on YOLOv8n[J]. Science Technology and Engineering, 2024, 24 (36): 15548-15557.
- [11] 王浩,张其猛,龚德成.复杂场景下的交通标志小目标检测算法[J].电子测量技术, 2025, 48(2): 158-169.
WANG H, ZHANG Q M, GONG D CH. Small-target traffic sign detection algorithm in complex scenes [J]. Electronic Measurement Technology, 2025, 48(2): 158-169.
- [12] 刘晶,刘俊伟.应用归一化通道注意力机制的 YOLOv7 交通标志检测算法[J].计算机工程与应用, 2025, 61(11): 249-258.
LIU J, LIU J W. YOLOv7 traffic sign detection algorithm with normalized channel attention mechanism [J]. Computer Engineering and Applications, 2025, 61 (11): 249-258.
- [13] 许明,屈泰澎,姜彦吉.改进 YOLOv7 在复杂场景下的交通标志检测算法[J].计算机工程, 2025, 51(2): 335-343.
XU M, QU T P, JIANG Y J. Improved YOLOv7 for traffic sign detection in complex scenes[J]. Computer Engineering, 2025, 51(2): 335-343.
- [14] 罗向龙,吕温馨,石镇岳,等.改进 YOLOv8n 的轻量化交通标志检测算法[J].激光与光电子学进展, 2025, 62(12): 422-433.
LUO X L, LYU W X, SHI ZH Y, et al. Lightweight traffic sign detection algorithm based on improved YOLOv8n [J]. Laser & Optoelectronics Progress, 2025, 62(12): 422-433.
- [15] OUYANG D L, HE S, ZHANG G ZH, et al. Efficient multi-scale attention module with cross-spatial learning [C]//ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP), 2023: 1-5.
- [16] 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.
LI J H, MIN W D, CHEN J J, et al. High-precision traffic sign detection model for complex scenes [J]. Computer Engineering, 2023, 49(11): 311-320.
- [17] HAN Y J, WANG F P, WANG W, et al. EDN-YOLO: Multi-scale traffic sign detection method in complex scenes[J]. Digital Signal Processing, 2024, 153: 104615.
- [18] 栾添添,顾雯莉,孙明晓,等.融合颜色不变量与多尺度特征的 ORB 充电桩定位算法研究[J].仪器仪表学报, 2025, 46(6): 361-369.
LUAN T T, GU W L, SUN M X, et al. Research on an ORB-based charging pile localization algorithm integrating color invariant and multi-scale features[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 361-369.
- [19] 俞林森,陈志国.融合前景注意力的轻量级交通标志检测网络[J].电子测量与仪器学报, 2023, 37(1): 21-31.
YU L S, CHEN ZH G. Lightweight traffic sign detection network with fused foreground attention[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 21-31.
- [20] 陈子昂,郭唐仪,隋立岩,等.基于 YOLOv5s 优化模型的道路交通标志异常状态检测[J].公路交通科技, 2024, 41(10): 8-16.
CHEN Z ANG, GUO T Y, SUI L Y, et al. Abnormal state detection of road traffic signs based on optimized YOLOv5s model[J]. Journal of Highway and Transportation Research and Development, 2024, 41(10): 8-16.
- [21] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [22] 蓝章礼,邢彩卓,张洪.基于改进 YOLOv5s 的被遮挡交通标志检测算法[J].计算机工程, 2025, 51(5): 361-369.
LAN ZH L, XING C ZH, ZHANG H. Occluded traffic sign detection algorithm based on improved YOLOv5s[J]. Computer Engineering, 2025, 51(5): 361-369.
- [23] HE Y, GUO M Q, ZHANG Y C, et al. NTS-YOLO: A nocturnal traffic sign detection method based on improved YOLOv5 [J]. Applied Sciences, 2025, 15(3):1578.
- [24] WANG J, SONG Z A, ZHANG Z Y, et al. Delineating sight occlusions of head-on traffic signboards under varying available sight distances using LiDAR point clouds [J]. Transportation Research Record, 2024, 2678(8): 596-609.
- [25] GOUDA M, BASYOUNY E K. Evaluation of traffic sign occlusion for autonomous vehicles using point cloud data [J]. Transportation Research Record, 2025, 2679(1): 1531-1546.
- [26] 陈丹,令陈佩,刘瑞瑜.新型 DRNet 结合 EIoU 的遮挡

- 目标分割模型[J]. 电子测量与仪器学报, 2025, 39(8): 209-217.
- CHEN D, LING CH P, LIU R Y. Novel DRNet occlusion target segmentation model combined with EIou[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 209-217.
- [27] XU Y H, DU B, ZHANG L F, et al. Self-ensembling attention networks: Addressing domain shift for semantic segmentation [C]//AAAI Conference on Artificial Intelligence, 2019, 33(1): 5581-5588.
- [28] LOU M, YU Y Z. OverLoCK: An overview-first-look-closely-next ConvNet with context-mixing dynamic kernels[C]//Computer Vision and Pattern Recognition Conference, 2025: 128-138.
- [29] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]//European Conference on Computer Vision, 2016: 21-37.
- [30] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [31] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in Neural Information Orocessing Systems, 2015, 28:91-99.
- [32] 秦伦明, 张云起, 崔昊杨, 等. 基于改进 RT-DETR 的极端天气下交通标志检测方法[J]. 电子测量技术, 2025, 48(9): 56-64.
- QIN L M, ZHANG Y Q, CUI H Y, et al. Traffic sign detection method in extreme weather based on improved RT-DETR [J]. Electronic Measurement Technology, 2025, 48(9): 56-64.
- [33] 刘美辰, 李杰, 陈廷伟. DTI-YOLO: 改进 YOLOv10s 的交通标志检测模型[J]. 计算机工程与应用, 2025, 61(17): 112-122.
- LIU M CH, LI J, CHEN T W. DTI-YOLO: An improved YOLOv10s model for traffic sign detection[J]. Computer Engineering and Applications, 2025, 61(17): 112-122.
- [34] PANG J M, CHEN K, SHI J P, et al. Libra R-CNN: Towards balanced learning for object detection[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 821-830.
- [35] ZHANG H K, CHANG H, MA B P, et al. Dynamic R-CNN: Towards high quality object detection via dynamic training [C]//European Conference on Computer Vision, 2020: 260-275.

作者简介

蓝章礼, 博士, 教授, 博士生导师, 主要研究方向为模式识别与图像处理等。

E-mail: lzl@cqjtu.edu.cn

文鸿(通信作者), 硕士研究生, 主要研究方向为模式识别与图像处理。

E-mail: 13627685983@163.com

张洪, 博士, 教授, 博士生导师, 主要研究方向为桥梁健康检测及无损检测、机器视觉算法及应用。

E-mail: hongzhang@cqjtu.edu.cn