

DOI: 10.20271/j.cnki.1673-9833.2026.3009

融入注意力机制的交通标志检测算法

彭杰, 于惠钧

(湖南工业大学 交通与电气工程学院, 湖南 株洲 412007)

摘要: 针对现有目标检测算法存在对交通标志识别准确率低、检测不完全等问题, 提出一种将注意力机制融入YOLO11n的交通标志检测算法。首先, 将卷积和注意力融合模块与YOLO11n主干部分结合, 通过融合卷积操作和注意力机制, 对图像的全局和局部特征进行有效建模, 以提升检测精度; 其次, 利用全局注意力机制模块融入YOLO11n颈部, 使模型对特征中的语义信息和位置信息提取更为充分, 进而提高了模型的特征表达能力; 最后, 添加一个小目标检测层, 保留更多浅层细节信息, 以增强深层和浅层语义信息的融合, 从而改善对小目标检测不完全的问题。实验结果证明, 改进后的算法在TT100K数据集中, 精确率、召回率、平均精度分别达83.9%, 70.7%, 82.4%, 与原模型YOLO11n相比较, 分别提高了5.7%, 2.7%, 6.3%, 证明了改进算法的有效性。

关键词: 交通标志检测; YOLO11; CAFM注意力机制; GAM注意力机制

中图分类号: TP391

文献标志码: A

文章编号: 1673-9833(2026)03-0063-07

引文格式: 彭杰, 于惠钧. 融入注意力机制的交通标志检测算法[J]. 湖南工业大学学报, 2026, 40(3): 63-69.

Traffic Sign Detection Algorithm with Attention Mechanism Incorporated

PENG Jie, YU Huijun

(School of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: In view of the flaws of low recognition accuracy and incomplete detection of traffic signs in existing target detection algorithms, a traffic sign detection algorithm has thus been proposed with an attention mechanism incorporated into YOLO11n. Firstly, the convolution and attention fusion module (CAFM) is integrated with the YOLO11n backbone, so as to effectively model both global and local features of images by combining convolution operations with attention mechanisms to enhance detection accuracy. Secondly, by incorporating the global attention mechanism module into the YOLO11n neck, the model is enabled to extract semantic and positional information from features more fully, thereby improving the feature expression ability of the model. Finally, a small target detection layer is added to retain more shallow detail information to enhance the fusion of deep and shallow semantic information, thus overcoming the incomplete detection of small targets. The experimental results show that the improved algorithm is characterized with a good accuracy, recall, and mean average precision (mAP) of 83.9%, 70.7%, and 82.4%, respectively, in the TT100K dataset. Compared with the original model YOLO11n, it improves by 5.7, 2.7, and 6.3 percentage points, verifying the effectiveness of the improvement.

Keywords: traffic sign detection; YOLO11; CAFM attention mechanism; GAM attention mechanism

收稿日期: 2024-12-23

作者简介: 彭杰, 男, 湖南工业大学硕士生, 主要研究方向为计算机视觉与目标检测, E-mail: 1501861966@qq.com

通信作者: 于惠钧, 男, 湖南工业大学教授, 硕士生导师, 主要研究方向为图像处理与模式识别, E-mail: arejunyu@foxmail.com

1 研究背景

随着智能辅助驾驶系统的发展，对实际道路中交通标志检测的需求与日俱增。通过识别交通标志，可以为驾驶员提供所需要的交通信息，引导驾驶员遵守交通规则，能显著减少交通违法与事故。同时，交通标志检测有助于提升道路通行效率，避免交叉路口拥堵，确保驾驶员和行人的安全。因此，交通标志检测在现代交通系统中具有重要意义^[1]。

目前，深度学习算法^[2]在交通标志检测任务中已有广泛应用，算法分为两阶段检测算法和单阶段检测算法^[3]。经典单阶段检测算法主要包括YOLO^[4-5]系列、SSD^[6]系列。Liang T. J.等^[7]提出了一种轻量级的交通标志检测算法，该算法基于YOLOv4使用轻量化Mobilenetv3^[8]网络和注意力机制(squeeze-and-excitation, SE)^[9]模块对原模型作出改进，但模型对特征信息提取不充分，且检测准确率较低。熊恩杰等^[10]设计了C2fGhost模块，提出了Ghost-YOLOv8交通标志检测算法，在减少模型参数数量的同时提高了检测精度，但改进后的算法平均精度整体较低，

也并未对算法的泛化能力作进一步验证。闫世洋等^[11]使用SCConv替换C2f中的Bottleneck，提出了SC-YOLOv8检测算法，其有效地改善了漏检和准确率低等情况。针对YOLO11n算法存在对交通标志识别不完全和检测精度较低等问题，本文提出了一种将注意力机制融入YOLO11n的交通标志检测算法。具体包括以下工作：1)引入CAFM(convolution and attention fusion module)注意力机制模块使局部特征与全局特征相融合，提升模型的检测精度；2)用GAM(global attention mechanism)注意力机制模块使模型对特征中的语义信息和位置信息提取更为充分；3)增加一个小目标检测层以增强深层和浅层语义信息的融合。

2 YOLO11n 算法原理与改进

2.1 YOLO11n 算法原理

Ultralytics团队于2024年9月提出YOLO11^[12]。Ultralytics团队提供了5种(从小到大依次为n、s、m、l、x)不同规模版本，本文选取YOLO11n为实验基础模型，其网络结构如图1所示。

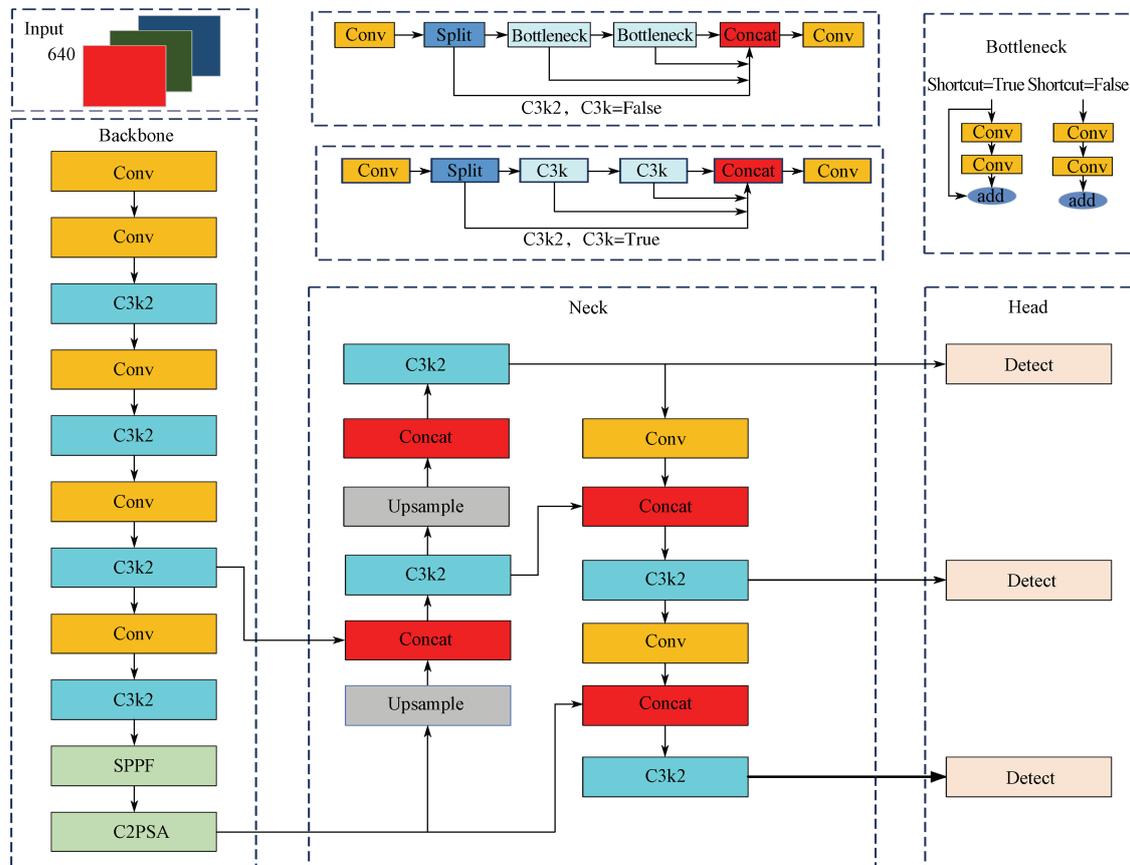


图1 YOLO11n 网络结构图
Fig. 1 YOLO11n network structure diagram

如图1所示, YOLO11n的网络结构由输入层、主干网络、特征融合层和检测层4部分组成。其中, 输入层(Input)用于对输入的图像进行预处理; 主干网络(Backbone)由Conv、C3k2、SPPF(spatial pyramid pooling fast, SPPF)和C2PSA等模块构成, 作为主要特征提取器。特征融合层(Neck)接收来自Backbone所生成的不同尺度特征, 并将其传输到检测层(Head)进行预测, 使模型能够有效地获取多尺度特征信息。Head接收来自Neck传递的特征图, 并对其进行检测, 输出图像中目标的边界框、标签类别和置信度。

2.2 融入注意力机制的算法

如图2所示, 课题组提出一种将注意力机制融入YOLO11n的交通标志检测算法。首先, 将CAFm注意力机制模块与YOLO11n主干部分结合, 对图像的全局和局部特征进行有效建模, 从而提升模型检测精度; 然后, 将GAM注意力机制模块融入YOLO11n颈部, 使模型对特征中的语义信息和位置信息提取更为充分; 最后, 增加一个小目标检测层, 用于改善模型存在的对小目标检测精度低、漏检等情况。实验证明, 改进后的算法能够有效改善YOLO11n在交通标志检测任务中检测精度低和检测不完全等问题。

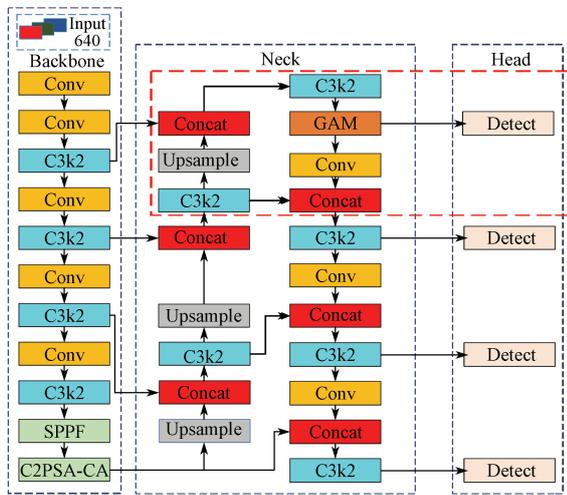


图2 融入注意力机制的YOLO11n

Fig. 2 YOLO11n with the attention mechanism incorporated

2.2.1 CAFm注意力机制

课题组使用CAFm^[13]注意力机制模块与YOLO11n中的Backbone的C2PSA模块结合为C2PSA-CA, 使局部特征与全局特征相融合, 进而提升模型的检测精度。

如图3所示, CAFm注意力机制模块主要由全局分支和局部分支两部分组成。其中, 全局分支为输入端的右侧分支, 采用自注意力机制, 能更全面地捕

捉特征信息; 局部分支为输入端的左侧分支, 侧重于保留更多的局部特征, 以提高模型对局部特征信息的利用率。

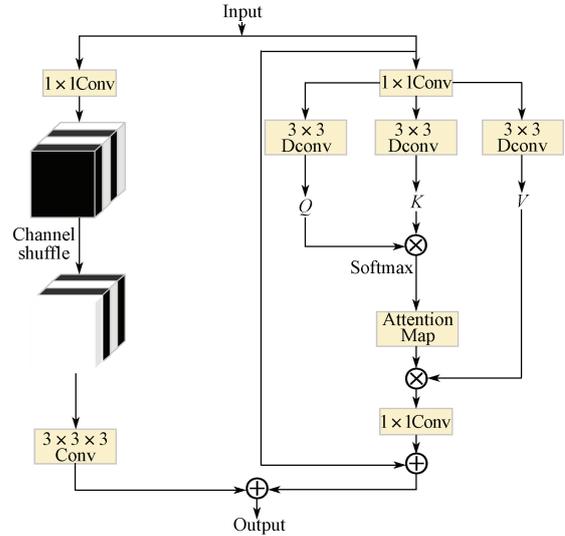


图3 CAFm注意力机制结构图

Fig. 3 CAFm attention mechanism structure diagram

在局部分支中, 为促进多通道特征间的充分融合, 首先, 采用 1×1 卷积层对通道维度进行统一调整; 其次, 通过通道混洗操作对调整后的特征做进一步融合, 该操作将输入特征按维度分组, 以提升融合效果; 之后, 将处理后的特征按对应维度重新组合, 形成新的输出张量; 最后, 利用一个 $3 \times 3 \times 3$ 卷积层对该张量进行更深层次的特征提取。局部分支由式(1)表示。

$$F_L = W_{3 \times 3 \times 3} (CS(W_{1 \times 1}(Y))) \quad (1)$$

式中: F_L 为局部分支的输出; $W_{1 \times 1}$ 为 1×1 卷积; $W_{3 \times 3 \times 3}$ 为 $3 \times 3 \times 3$ 卷积; CS为通道混洗操作; Y 为输入特征。

在全局分支中, 同样利用 1×1 的卷积对输入特征的通道维度进行处理。接着, 将特征信息分别用3组 3×3 深度可分离卷积生成所需的 Q 、 K 、 V , 然后对 Q 、 K 进行重组, 重组后为 Q_1 、 K_1 , 将其通过Softmax归一化处理得到对应的Attention Map, 再将 V 通过Attention Map进行加权处理, 使其能赋予重要信息更高的权重, 输出结果为 V_1 。最后, 再次利用 1×1 的卷积对通道维度进行复原化处理, 以使其与残差进行连接后, 再与局部分支的输出融合。全局分支由式(2)(3)表示。

$$F_G = W_{1 \times 1} Attention(Q, K_1, V_1) + Y, \quad (2)$$

$$Attention(Q_1, K_1, V_1) = V_1 Softmax(Q_1 K_1 / \alpha) \quad (3)$$

式(2)(3)中: F_G 为全局分支的输出; $Attention(Q_1, K_1, V_1)$ 为加权后的输出特征图; V_1 为 V 的加权值; α 为可变的缩放系数, 用于调整 K 和 Q

的矩阵乘法幅度。

CAFM注意力机制模块的输出结果 F_{Out} 由式(4)表示。

$$F_{Out} = F_L + F_G. \quad (4)$$

2.2.2 GAM注意力机制

为提高模型对小目标交通标志的特征表达能力,本文引入GAM^[14]注意力机制模块,其结构见图4。

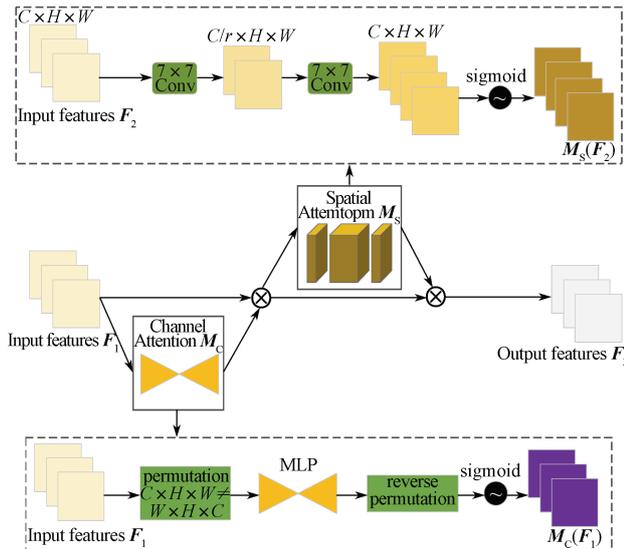


图4 GAM注意力机制结构图

Fig. 4 GAM attention mechanism structure diagram

如图4所示,GAM注意力机制模块主要由通道注意力模块和空间注意力模块两部分组成,能够使模型聚焦于关键信息,有效降低对图片背景中的冗余特征信息处理。通道注意力模块采用空间排列方法对特征图里的特征信息进行存储处理,处理后的输入特征再通过多层感知机(MLP)来放大各个通道之间的空间相关性,最后通过sigmoid对特征进行处理。空间注意力模块通过两个卷积运算进一步融合空间特征信息。首先,通过第一个 7×7 的卷积运算减少通道数量,进而提高模型计算效率;接着,使用一个 7×7 的卷积运算将其通道数量调整为与输入特征一致;最后通过sigmoid对特征进行处理。为保留更多的细节特征映射,模块去除了最大池化操作,为保证与通道注意力模块的关联性,缩放因子应与其保持一致。

输入特征图 F_1 、中间状态 F_2 和输出特征图 F_3 的关系如式(5)(6)所示。

$$F_2 = M_c(F_1) \otimes F_1, \quad (5)$$

$$F_3 = M_s(F_2) \otimes F_2. \quad (6)$$

式(5)(6)中: M_c 为通道注意力图; M_s 为空间注意力图; \otimes 为基于元素的乘法。

2.2.3 小目标检测层

针对实际道路场景下交通标志小、目标数量多、像素占比低的问题,课题组引入一个小目标检测层(图2红色虚线框所示),以缓解模型在深层网络中细节特征易被大范围特征覆盖而导致的漏检与精度下降。

具体而言,先将颈部的上采样输出与主干部分中的深层特征层进行拼接处理,经C3k2模块增强模型对深层语义信息的提取;随后,为进一步提升特征表达能力,再次进行上采样操作;接着,将该特征与主干部分中的浅层特征层相融合,依法形成的特征信息结合了深层语义信息与浅层位置信息,旨在使模型获得更为全面、丰富的特征表示;最后,通过GAM注意力机制对融合后的特征进行处理,并将其送入新增的检测头进行检测。该新增的小目标检测层,通过补充小目标的细节特征,实现了深层语义与浅层定位特征的融合,增强了特征的语义丰富性与表达力,不仅扩大了模型的检测范围,也有效缓解了模型对小目标检测的漏检问题。

3 实验设计与结果分析

3.1 数据集与实验环境

TT100K^[15]是由清华大学和腾讯实验室联合整理公开的大型交通标志数据集。该数据集有100 000张图像,来源于中国多个城市拍摄的街景全景图,包含类别有指示、禁令及警告标识三大类,共有交通标志小类别221种。由于部分类别的交通标志样本实例过少,为避免影响训练实验结果,经筛选后,本文整合了45类交通标志,其中交通标志类别实例图均大于100张作为数据集,训练集数据6 793张,验证集数据1 949张,测试集数据996张。

实验所用操作系统为Ubuntu22.04,Python版本为3.12,GPU型号为RTX3080Ti,在Pytorch2.3.0深度学习框架下进行实验,具体训练参数设置见表1。

表1 训练参数设置

Table 1 Training parameter settings

参数名称	配置	参数名称	配置
epochs	200	optimizer	SGD
batchsize	16	momentum	0.937
workers	8	cuda	Cuda12.1
imgsz	640	lr0	0.01

3.2 评价指标

本文使用精确率(P)、召回率(R)、平均精度(mAP)等作为评价指标。

其中 P 用于衡量模型预测为正类(TP)的样本中,实际为正类($TP+FP$)的比例,如式(7)所示:

$$P = \frac{TP}{TP + FP} \quad (7)$$

R 用于衡量所有实际为正类(TP)的样本中,模型正确预测为正类($TP+FN$)的比例,如式(8)所示:

$$R = \frac{TP}{TP + FN} \quad (8)$$

AP 为单个类别平均精度, mAP 为所有类别的平均精度, n 为总类别数。 $mAP@0.5$ 表示IOU阈值为0.5时的总类别平均精度, $mAP@0.5:0.95$ 表示IOU阈值从0.5到0.95(以0.05为步长)范围内多个阈值下的平均精度,具体计算公式如下:

$$AP = \int_0^1 P(r)dr, \quad (9)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i, \quad (10)$$

$$mAP@0.5 = \frac{1}{n} \sum_{i=1}^n AP@0.5_i, \quad (11)$$

$$mAP@0.5:0.95 = \frac{1}{10} mAP@0.5 + \frac{1}{10} mAP@0.55 + \dots + \frac{1}{10} mAP@0.95 \quad (12)$$

3.3 消融实验

为验证本文所添加模块的有效性,在TT100K数据集上以YOLO11n为基线模型进行了消融实验,消融实验结果如表2所示。其中①表示YOLO11n原模型,②、③、④表示分别在上一次实验模型的基础上逐步添加GAM注意力机制模块、CAFm注意力机制模块和小目标检测层。

表2 消融实验结果

Table 2 Results of ablation experiments

模型	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	参数量/10 ⁶
①	78.2	68.0	76.1	59.2	2.59
②	80.4	67.7	78.2	60.4	2.67
③	81.8	68.8	79.7	61.3	2.79
④	83.9	70.7	82.4	62.9	2.97

根据表2可知,首先添加GAM注意力机制模块后, P 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别提高了2.2%,2.1%,1.2%,表明该模块的添加使模型对特征信息的提取更为充分,进而提高了检测精度。

接着,添加CAFm注意力机制模块后, P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 均有所提升,分别提高了1.4%,1.1%,1.5%,0.9%,可见该模块的加入提升了模型的整体检测性能。

最后,添加小目标检测层后(本文模型),

进一步增强了模型对小目标的感知能力, P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别达到了83.9%,70.7%,82.4%,62.9%,较YOLO11n原模型提高了5.7%,2.7%,6.3%,3.7%。综合评估下,本文改进算法虽增加了一定的模型参数量,但在检测精度方面获得了有效的提升,证明了本文所用改进模块对交通标志识别的有效性。

3.4 对比实验

为验证本文算法在交通标志检测较现有算法的优势,在同一数据集和实验环境下将本文算法与YOLOv5n、YOLOv6^[16]、YOLOv8n和近期交通标志检测算法^[17-18]进行对比实验,结果如表3所示。

表3 对比实验结果

Table 3 Results of comparison experiments

模型	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	参数量/10 ⁶
YOLOv5n	73.2	63.4	71.6	53.7	2.51
YOLOv6	67.1	59.4	65.7	49.5	4.29
YOLOv8n	80.0	68.8	77.2	59.3	3.01
文献[17]	70.0	67.9	71.8	53.9	1.95
文献[18]	70.2	63.3	67.1	49.1	3.80
本文算法	83.9	70.7	82.4	62.9	2.97

根据表3可知,本文改进算法在TT100K数据集上, P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别为83.9%,70.7%,82.4%,62.9%。从整体来看,除在模型参数量指标上不如文献[17]和YOLOv5n外,本文算法在各项评价指标中较表内其余算法拥有一定优势,有效证明了本算法改进在交通标志检测任务中的理论可行性。

利用CCTSDB^[19]数据集对本文算法的泛化能力进行测试,结果如表4所示,其中①为原模型YOLO11n,②为本文改进算法。

表4 泛化实验结果

Table 4 Results of generalization experiments

模型	P/%	R/%	mAP@0.5/%	mAP@0.5:0.95/%	参数量/10 ⁶
①	85.4	69.0	76.0	47.3	2.59
②	88.5	71.4	81.1	49.8	2.97

根据表4可知,在CCTSDB数据集上本文改进算法相较于原模型YOLO11n, P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$,分别提高了3.1%,2.4%,5.1%,2.5%,说明本文改进算法具备一定的泛化能力。

3.5 算法验证

在TT100K数据集上进行了交通标志检测结果可视化对比,结果如图5所示。在图I的对比图中,本文改进算法置信度显著高于原模型;在图II、III的对比图中,原模型出现了不同程度的漏检,本文

改进算法将其正确识别出，且本文改进算法在与原模型均正确检测出的交通标志中拥有更高的置信度；在图IV的对比图中，原模型将限速 30 km/h 的交通标志误检为 40 km/h。综合上述对比分析结果可知，本文改进算法拥有更高的识别精度，并改善了误检和漏检等情况。



a) 图 I 的 YOLO11n 检测图 b) 图 I 的改进算法检测图



c) 图 II 的 YOLO11n 检测图 d) 图 II 的改进算法检测图



e) 图 III 的 YOLO11n 检测图 f) 图 III 的改进算法检测图



g) 图 IV 的 YOLO11n 检测图 h) 图 IV 的改进算法检测图

图 5 可视化结果对比

Fig. 5 Comparison of visualization results

4 结语

本文提出一种将注意力机制融入 YOLO11n 的交通标志检测算法，有效改善了检测精度低和检测不完全等问题。首先，引入 CAFM 注意力机制模块使局

部特征与全局特征相融合，提升模型检测精度；其次，添加 GAM 注意力机制模块使模型对特征中的语义信息和位置信息提取更为充分；最后，增加一个小目标检测层以增强深层和浅层语义信息的融合，提升模型对小目标的感知能力，进而减少误检和漏检等情况。

实验结果表明，本文改进算法在 TT100K 数据集上 P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别达到了 83.9%、70.7%、82.4%、62.9%，较 YOLO11n 原模型提高了 5.7%、2.7%、6.3%、3.7%；在 CCTSDB 数据集上，上述 4 个评价指标分别提高了 3.1%、2.4%、5.1%、2.5%，有效验证了模型的泛化能力。本文改进算法能够有效改善对交通标志存在的准确率低、误检和漏检等问题，从而减少交通违法和事故的发生。在后续工作中应将模型部署于实际道路场景，在实际中对模型进一步探索。

参考文献:

- [1] LIU P L, XIE Z Y, LI T J. UCN-YOLOv5: Traffic Sign Object Detection Algorithm Based on Deep Learning[J]. IEEE Access, 2023, 11: 110039–110050.
- [2] 俞建峰. 深度学习: 智能机器人应用的理论与实践 [M]. 北京: 化学工业出版社, 2024: 29–41.
YU Jianfeng. Deep Learning: Theory and Practice of Intelligent Robot Application[M]. Beijing: Chemical Industry Press, 2024: 29–41.
- [3] 曹家乐, 李亚利, 孙汉卿, 等. 基于深度学习的视觉目标检测技术综述 [J]. 中国图象图形学报, 2022, 27(6): 1697–1722.
CAO Jiale, LI Yali, SUN Hanqing, et al. A Survey on Deep Learning Based Visual Object Detection[J]. Journal of Image and Graphics, 2022, 27(6): 1697–1722.
- [4] 邵延华, 张 铎, 楚红雨, 等. 基于深度学习的 YOLO 目标检测综述 [J]. 电子与信息学报, 2022, 44(10): 3697–3708.
SHAO Yanhua, ZHANG Duo, CHU Hongyu, et al. A Review of YOLO Object Detection Based on Deep Learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697–3708.
- [5] 孙玉林. 计算机视觉从入门到进阶实战: 基于 PyTorch[M]. 北京: 化学工业出版社, 2024: 131–173.
SUN Yulin. Computer Vision from Entry to Advanced Combat: Based on PyTorch[M]. Beijing: Chemical Industry Press, 2024: 131–173.
- [6] 汪 宋, 费树岷. SSD(Single Shot MultiBox Detector) 目标检测算法的研究与改进 [J]. 工业控制计算机, 2019, 32(4): 103–105.
WANG Song, FEI Shumin. Research and Improvement of SSD(Single Shot MultiBox Detector) Target Detection

- Algorithm[J]. *Industrial Control Computer*, 2019, 32(4): 103–105.
- [7] LIANG T J, BAO H, PAN W G, et al. Traffic Sign Detection via Improved Sparse R-CNN for Autonomous Vehicles[J]. *Journal of Advanced Transportation*, 2022(1): 3825532.
- [8] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 1314–1324.
- [9] 任欢, 王旭光. 注意力机制综述[J]. *计算机应用*, 2021, 41(增刊1): 1–6.
REN Huan, WANG Xuguang. A Summary of Attention Mechanism[J]. *Journal of Computer Applications*, 2021, 41(S1): 1–6.
- [10] 熊恩杰, 张荣芬, 刘宇红, 等. 面向交通标志的 Ghost-YOLOv8 检测算法[J]. *计算机工程与应用*, 2023, 59(20): 200–207.
XIONG Enjie, ZHANG Rongfen, LIU Yuhong, et al. Ghost-YOLOv8 Detection Algorithm for Traffic Signs[J]. *Computer Engineering and Applications*, 2023, 59(20): 200–207.
- [11] 闫世洋, 罗素云. 基于 SC-YOLOv8 的交通标志检测算法研究[J]. *电子测量技术*, 2024, 47(15): 117–124.
YAN Shiyang, LUO Suyun. Research on Traffic Sign Detection Algorithm Based on SC-YOLOv8[J]. *Electronic Measurement Technology*, 2024, 47(15): 117–124.
- [12] ALKHAMMASH E H. Multi-Classification Using YOLOv11 and Hybrid YOLO11n-MobileNet Models: A Fire Classes Case Study[J]. *Fire*, 2025, 8(1): 17.
- [13] HU S, GAO F, ZHOU X W, et al. Hybrid Convolutional and Attention Network for Hyperspectral Image Denoising[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 5504005.
- [14] 张震, 肖宗荣, 李友好, 等. 基于改进 YOLOv7 的高风险区工程车辆识别算法[J]. *郑州大学学报(工学版)*, 2025, 46(5): 1–8.
ZHANG Zhen, XIAO Zongrong, LI Youhao, et al. Construction Vehicles Recognition Algorithm Based on Improved YOLOv7 in High Risk Areas[J]. *Journal of Zhengzhou University (Engineering Science)*, 2025, 46(5): 1–8.
- [15] ZHU Z, LIANG D, ZHANG S H, et al. Traffic-Sign Detection and Classification in the Wild[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 2110–2118.
- [16] LI C, LI L, JIANG H, et al. YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications[J]. *Arxiv Preprint*, 2022, Arxiv: 2209.02976.
- [17] 赵会鹏, 曹景胜, 潘迪敬, 等. 改进 YOLOv8 算法的交通标志小目标检测[J]. *现代电子技术*, 2024, 47(20): 141–147.
ZHAO Huipeng, CAO Jingsheng, PAN Dijing, et al. Traffic Sign Small Target Detection Based on Improved YOLOv8 Algorithm[J]. *Modern Electronics Technique*, 2024, 47(20): 141–147.
- [18] TANG Y, HAN K, GUO J, et al. GhostNetv2: Enhance Cheap Operation with Long-Range Attention[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 9969–9982.
- [19] ZHANG L L, YANG K, HAN Y C, et al. TSD-DETR: A Lightweight Real-Time Detection Transformer of Traffic Sign Detection for Long-Range Perception of Autonomous Driving[J]. *Engineering Applications of Artificial Intelligence*, 2025, 139: 109536.

(责任编辑: 申剑)