基于改进RT-DETR网络的小目标识别算法研究*

胡建功[1] 卜旭阳[2,3] 高万里[3] 王全伟[2] 秦晋[3]

（1.太原学院，太原 030032；2.太原科技大学机械工程学院，太原 030024；3.纽科伦（新乡）起重机有限公司，新乡 453400）

【摘要】针对RT-DETR（Real-Time Detection Transformer）网络在复杂场景与小目标检测中存在的精度不足与速度受限问题，提出了一种面向车辆图像的改进检测算法。该算法通过引入空间位置关系建模，增强对车辆、行人等小尺度目标的特征捕获能力，并采用门控机制提升网络的非线性建模性能。同时，通过分离高频与低频细节信息，结合特征图的分割与拼接操作，实现了无信息丢失的特征采样。通过将卷积单元Conv和批量归一化单元BN融合处理来减少中间处理环节和内存消耗，提高计算效率和优化模型性能。试验结果表明，相较于原始RT-DETR网络，改进算法在mAP50、mAP50∶95、精度及召回率上分别提升了6%、4.5%、4.2%与4%。因此，优化主干网络结构并强化多尺度特征融合，聚焦细粒度信息与空频域特征，是提升复杂环境下车辆检测性能的有效策略。

主题词：RT-DETR 车辆识别 特征采样 多尺度特征融合 空频域特征

中图分类号：TP391.7 **文献标志码：**A **DOI:** 10.19620/j.cnki.1000-3703.20250438

Research on Small Target Recognition Algorithm Based on Improved RT-DETR Network

Hu Jiangong[1], Bu Xuyang[2,3], Gao Wanli[3], Wang Quanwei[2], Qin Jin[3]

（1. Taiyuan University, Taiyuan 030032; 2. School of Mechanical Engineering, Taiyuan University of Science and Technology, Taiyuan 030024; 3. Newcologne (Xinxiang) Crane Co., Ltd., Xinxiang 453400）

【Abstract】To address the issues of insufficient accuracy and limited speed of the RT-DETR (real-time detection transformer) network in complex scenarios and small object detection, an improved detection algorithm for vehicle images is proposed. This algorithm enhances the ability to capture features of small-scale objects such as vehicles and pedestrians by introducing spatial positional relationship modeling and improves the network's nonlinear modeling performance through a gating mechanism. At the same time, by separating high-frequency and low-frequency detail information and combining feature map segmentation and stitching operations, feature sampling is achieved without information loss. By integrating convolution units (Conv) and batch normalization units (BN) to reduce intermediate processing steps and memory consumption, computational efficiency is increased and model performance is optimized. Experimental results show that compared to the original RT-DETR network, the improved algorithm increases mAP50, mAP50∶95, precision, and recall by 6%, 4.5%, 4.2%, and 4%, respectively. Therefore, optimizing the backbone network structure and strengthening multi-scale feature fusion, focusing on fine-grained information and spatial-frequency domain features, is an effective strategy to improve vehicle detection performance in complex environments.

Key words: RT-DETR, Vehicle recognition, Feature sampling, Multi-scale feature fusion, Spatio-frequency domain features

【引用格式】胡建功, 卜旭阳, 高万里, 等. 基于改进RT-DETR网络的小目标识别算法研究[J]. 汽车技术, 2026(8): 12-18.

HU J G, BU X Y, GAO W L, et al. Research on Small Target Recognition Algorithm Based on Improved RT-DETR Network[J]. Automobile Technology, 2026(8): 12-18.

*基金项目：山西省重点研发项目（2020L0360）。

通信作者：卜旭阳（1995—），男，硕士学位，主要研究方向为机械设计理论与设计、智能优化算法研究，948909213@qq.com。

1 前言

随着信息技术的快速发展，自动驾驶技术正日益深入现代社会的各个应用场景。在这一背景下，车辆检测作为自动驾驶系统中实现安全导航、路径规划与动态避障等核心功能的基础环节，需具备在复杂多变行车环境下快速、准确识别与定位周边车辆的能力。

近年来，神经网络技术的快速发展推动了目标检测技术的进步。DETR（Detection Transformer）网络[1]作为首个将Transformer架构端到端应用于目标检测的模型，通过将三维特征图展平为一个二维序列，并借助二分图匹配策略寻找最优预测-真实框对应关系，摒弃了传统检测方法中依赖锚框设计及非极大值抑制后处理的流程，从而显著简化了检测流程。然而，与FasterR-CNN等经典模型相比，DETR通常需要多达500个训练周期才能收敛，其缓慢的训练效率限制了其在实时场景中的应用。为此，RT-DETR网络[2]应运而生，该模型通过高效混合编码器（Efficient Hybrid Encoder，EHE）实现全局上下文建模与多尺度特征融合，引入IoU（Intersection over Union）感知查询选择，有效提升了推理速度。尽管如此，DETR与RT-DETR在应对复杂交通场景时，仍存在灵活性不足、注意力稀疏等问题[3]。

针对上述问题，本文聚焦于提升RT-DETR在复杂交通环境下的检测性能，重点解决其在实际应用中存在的漏检、误检及精度不足等问题。通过对主干网络进行系统性优化，期望构建一种能够兼顾细节感知、上下文建模与高效上采样的新型网络架构，以增强模型在真实场景中的适应性与鲁棒性。

2 RT-DETR算法

RT-DETR模型基于Transformer架构，其核心创新在于高效混合编码器与IoU感知查询选择技术的协同工作，这使其在检测精度与推理速度间取得了出色平衡，从而实现了优异的实时性能。图1展示了该模型的网络结构[4]。

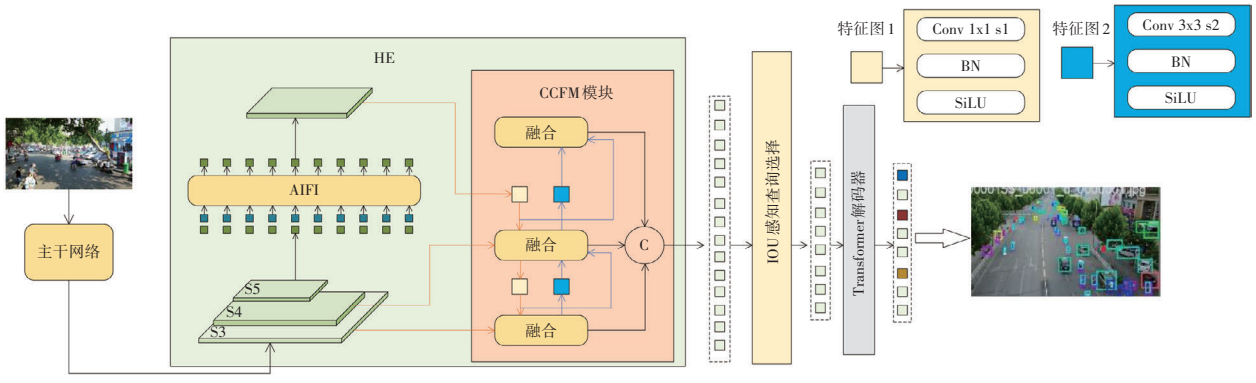


图1 RT-DETR网络结构图

RT-DETR模型由主干网络ResNet、混合编码器（HE）和Transformer解码器构成。HE采用解耦设计，内含负责高层特征上下文建模的AIFI（Attention-based Intra-scale Feature Interaction）模块与负责多尺度特征融合的CCFM（Cross-Scale Feature Fusion Module）模块。然而，在复杂环境中，该模型对于小目标及被遮挡目标的检测效果不佳，易出现漏检与误检，检测精度尚需进一步优化。

3 基于RT-DETR的改进优化算法

本文针对RT-DETR网络的改进主要涵盖以下3个方面：

a. 主干网络优化。引入RepCSPNet模块以替换原有结构，增强特征提取的稳健性与效率[5]。

b. 多尺度特征增强。通过集成SPD（Spatial Pyramid Dilated）模块与OFI（Optical Fiber Identifier）模块，提升模型在空域和频域的多尺度特征表示能力[6]。

c. 采样机制改进。通过CAFU模块优化传统采样过程，降低计算复杂度[7]。

3.1 RepCSPNet主干网络

主干网络的特征提取能力是目标检测性能的关键。为提升小目标的特征捕捉效果，本文通过引入改进后的CSPNet，结合RepNBottleneck和RepCSPNet来改进主干网络[8-9]，其结构如图2所示。

卷积单元的作用是对输入图像进行卷积处理，生成相应的特征矩阵。其表达式为：

$$Conv(\boldsymbol{X}) = W(\boldsymbol{X}) + b \tag{1}$$

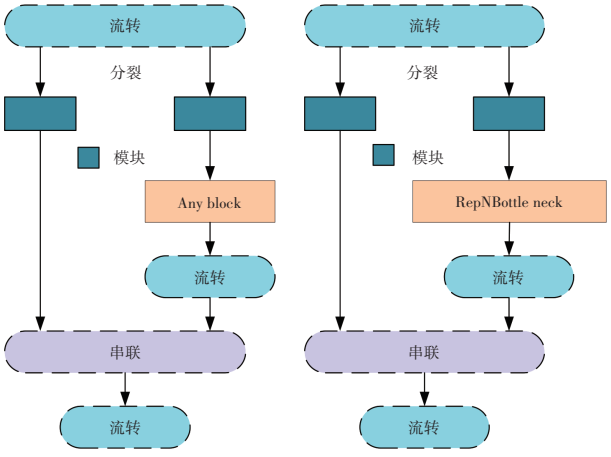
式中：$W(\boldsymbol{X})$为卷积权重并作用于矩阵$\boldsymbol{X}$，b为偏置项，$Conv()$为卷积运算。

批量归一化单元BN主要解决内部协变量偏移问

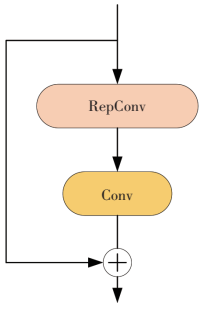
题，用于网络的中间训练过程，表达式为：

$$BN(X)=\gamma\frac{X-X_{\text{mean}}}{\sqrt{X_{\text{var}}}}+\beta \tag{2}$$

式中：参数γ、β为学习参数，分别用于控制尺度和偏移量；X_{mean}和X_{var}分别为特征矩阵X的均值和离散方差；$BN(X)$为归一化函数。



（a）CSPNet模块　　（b）RepCSPNet模块



（c）RepNBottleneck模块

图2　CSPNet、RepCSPNet、RepNBottleneck模块结构

通过将卷积单元和批量归一化单元BN合并为一个整体得到RepConv，表达式为：

$$\begin{aligned}BN(Conv(X))&=\gamma\frac{X-X_{\text{mean}}}{\sqrt{X_{\text{var}}}}+\beta\\&=\frac{\gamma W(X)}{\sqrt{X_{\text{var}}}}+\left(\frac{\gamma(b-X_{\text{mean}})}{\sqrt{X_{\text{var}}}}+\beta\right)\end{aligned} \tag{3}$$

同时，借助跨阶段RepCSPNet来优化RT-DETR主干网络特征提取，再连接多个RepCSPNet模块，提高网络的学习能力和特征提取能力。

3.2　多尺度感知模块MSOP优化

在传统网络中，基于步幅卷积与池化的下采样操作是导致小目标空间信息丢失、检测性能受限的主要原因之一。为突破此局限，本研究构建了一个名为MSOP（Multi-Scale Offset-aware Pooling）的多尺度特征增强模块，通过空域与频域的双重路径来提升特征表达能力[10-12]。其中，MSOP模块中最为核心的2个模块为：SPD模块和OFI模块，如图3和图4所示。

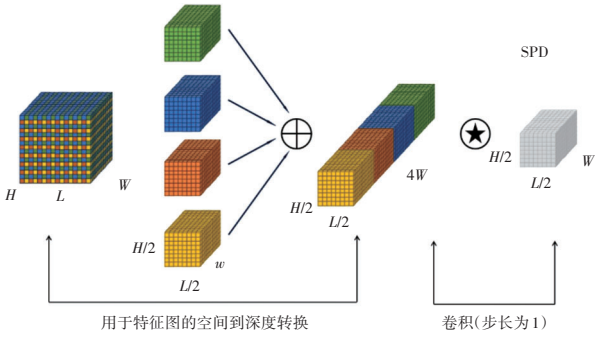


图3　SPD模型

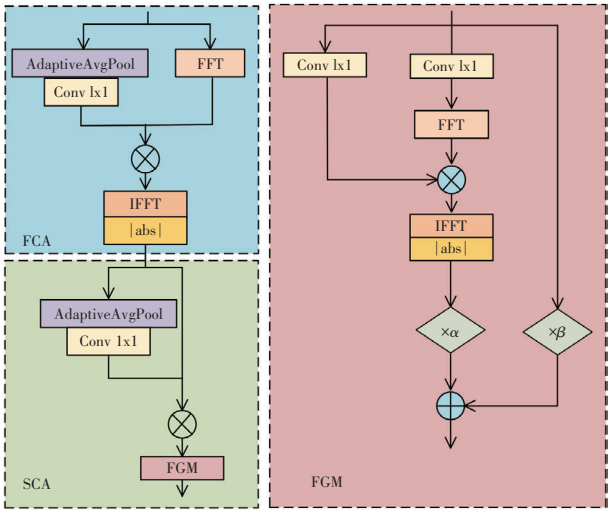


图4　OFI模块流程

SPD模块的核心在于对输入特征图进行空间分解与融合，以捕捉更丰富的小目标细节。其关键步骤在于将特征图$\boldsymbol{X}$分解为4个像素互补的子特征图，该过程可形式化描述为：

$$\begin{cases}\boldsymbol{X}_1=\boldsymbol{X}[\cdots,::2,::2]\\\boldsymbol{X}_2=\boldsymbol{X}[\cdots,1::2,::2]\\\boldsymbol{X}_3=\boldsymbol{X}[\cdots,::2,1::2]\\\boldsymbol{X}_4=\boldsymbol{X}[\cdots,1::2,1::2]\end{cases} \tag{4}$$

式中：$\boldsymbol{X}_1$、$\boldsymbol{X}_2$、$\boldsymbol{X}_3$、$\boldsymbol{X}_4$为输入特征图矩阵$\boldsymbol{X}$的4个子特征图矩阵。

式（4）通过多尺度融合，SPD将这些子特征图矩阵连接起来，表达式为：

$$\boldsymbol{X}_{\text{out}}=Conv(Concat(\boldsymbol{X}_1,\boldsymbol{X}_2,\boldsymbol{X}_3,\boldsymbol{X}_4)) \tag{5}$$

式中：$Conv(\ )$为卷积函数，$Concat(\ )$为连接函数，$\boldsymbol{X}_{\text{out}}$为多尺度融合后的特征图矩阵。

OFI模块通过聚合多尺度深度特征并结合分离卷积来捕获上下文信息，以此提升模型的表征能力。

3.3　CAFU模块

针对传统上采样方法（如双线性插值与去卷积）的

固有局限性，本文提出一种新型上采样模块CAFU（Channel Attention Feature Upsampling）。该模块旨在通过利用上下文信息与实现特征内容的自适应重组，以达成更高效的上采样效果[12-13]。该模块的工作流程主要分为3个部分：压缩、权重生成和重组。具体如下：

a. 压缩过程：首先对主干网络提取的特征图进行通道与空间维度的协同压缩。通过有选择的通道降维与空间下采样，在降低计算复杂度的同时，初步聚焦于关键信息区域，实现特征的聚焦。

b. 权重生成：基于压缩后的特征，分析其通道间的重要性分布，生成一组可学习的权重向量，用于量化不同特征通道的贡献程度。

c. 重组：利用所得权重对原始特征进行重新加权与结构重组，增强有用信号并抑制冗余信息，最终输出经净化和强化的特征图。

综合上述对主干网络、MSOP多尺度模块的优化以及CAFU上采样模块的引入，本文构建了一种全新的改进型RT-DETR图像检测算法，其整体架构如图5所示。

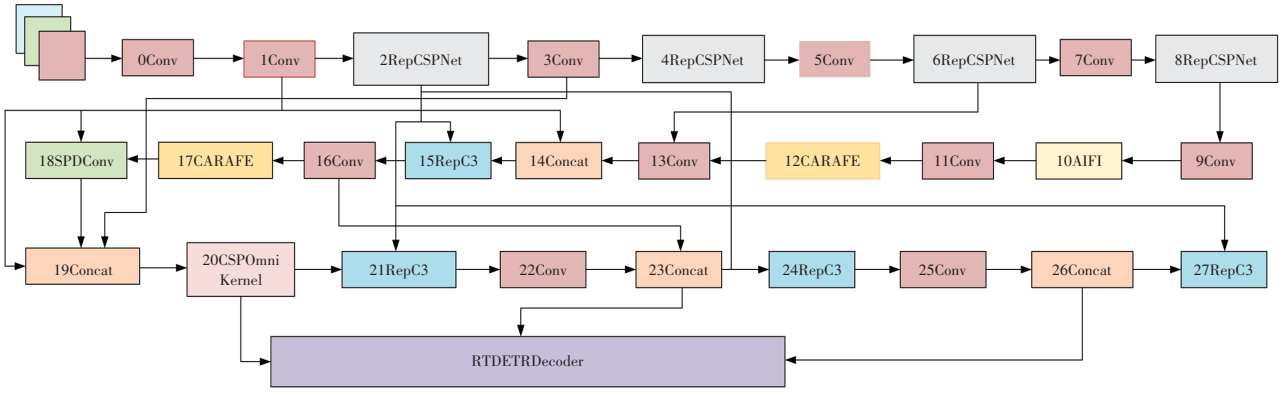


图5　改进后的RT-DETR图像识别算法

4　试验设计与结果分析

4.1　试验环境配置

本研究的试验环境配置为Windows 10操作系统与NVIDIA RTX 4060 GPU。所有模型均采用Python编程语言，并基于PyTorch深度学习框架实现。试验采用公开的VisDrone2019数据集[14]，该数据集规模为12 000张图像，所含目标类别包括行人（pedestrian）、自行车（bicycle）、轿车（car）、公共汽车（bus）、摩托车（motor）、厢式货车（van）、卡车（truck）等对象。模型的输入图像尺寸统一调整为640像素×640像素，训练过程共进行300个训练轮次，初始学习率设置为0.000 1。

4.2　评价指标

模型的性能通过平均精度均值（mAP）、准确率（Precision）、召回率（Recall）、mAP50∶95及参数量等指标进行综合评价。准确率$P_{\text{precision}}$与召回率R_{recall}的定义如下：

$$P_{\text{precision}}=\frac{T_{\text{P}}}{T_{\text{P}}+F_{\text{P}}} \tag{6}$$

$$R_{\text{recall}}=\frac{T_{\text{P}}}{T_{\text{P}}+F_{\text{N}}} \tag{7}$$

式中：T_{P}为真正例，F_{N}为假反例，F_{P}为假正例。

mAP为所有标签平均精度总和与所有类别总数的商。mAP表示为：

$$mAP=\frac{\sum_{k=1}^{K}AP_k}{K} \tag{8}$$

式中：K为类别的数量，AP_k为第k个类别AP值。

其中mAP50表示为λ_{IoU}=0.5时的平均精度值。mAP50∶95为在多个不同的λ_{IoU}阈值下计算模型的平均精度（通常是从0.5到0.95，步长为0.05）。

神经网络的参数量越少、精度越高说明网络越优越。

4.3　对比试验

为了验证改进后的RT-DETR算法的有效性，在相同条件的试验环境下进行了对比试验。对比的算法包含YOLOv5[15]、YOLOv8[16]、RTDETR-R18[17]、RTDETR-R34[18]、RTDETR-R50[19]等。尺寸图像设置为480像素×480像素、640像素×640像素、800像素×800像素等3种。试验结果如表1所示。

通过表1可知，改进之后的网络相较于RTDETR-R18网络mAP50提升了6%，mAP50∶95提升了4.5%。

4.4　消融试验

本研究通过消融试验以评估各模块的贡献，并对试验组进行统一命名：将RT-DETR网络、RepCSPNet模块分别简写为RT网络、RepCSP模块，并且对各组试验分别命名为RT-RepCSP网络、RT-RepCSP-SOEP网络（其中SOEP模块的作用为：自适应处理遮挡和光照极端变化等问题）、RT-RepCSP-

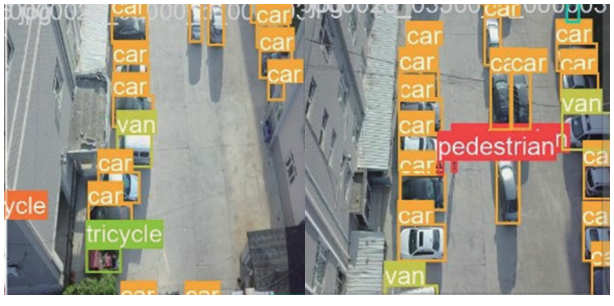
CARAFE网络（其中CARAFE模块的作用为：保留图像细节，优化图像边缘）、RT-RepCSP-SOEP-CARAFE网络，RT-R18网络，各组试验的直观对比与结果分析如图6和图7所示。

表1　不同模型试验结果

模型	输入尺寸/像素×像素	mAP50	mAP50:95	参数量/×10⁶个
RTDETR-R50	640×640	0.865	0.565	41.6
RTDETR-R34	640×640	0.825	0.537	31.1
RTDETR-R18	640×640	0.816	0.525	19.9
YOLOv8n	640×640	0.787	0.491	3.0
YOLOv5m	640×640	0.821	0.522	20.9
RTDETR-R18	480×480	0.804	0.518	19.9
RTDETR-R18	800×800	0.832	0.532	19.9
改进后的RT-RTDETR	640×640	0.877	0.565	11.8
改进后的RT-RTDETR	480×480	0.832	0.553	11.8
改进后的RT-RTDETR	800×800	0.885	0.593	11.8



（a）RT-R18　　（b）RT-RepCSP

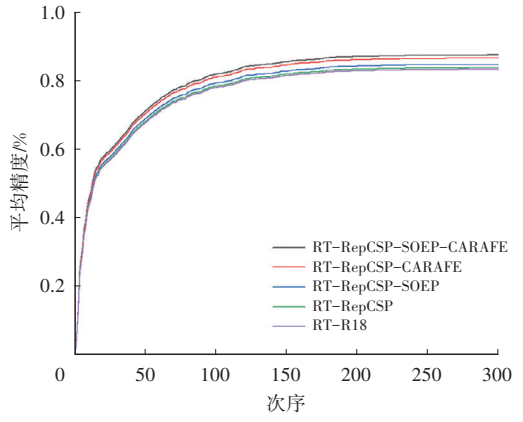


（c）RT-RepCSP-SOEP　　（d）RT-RepCSP-CARAFE

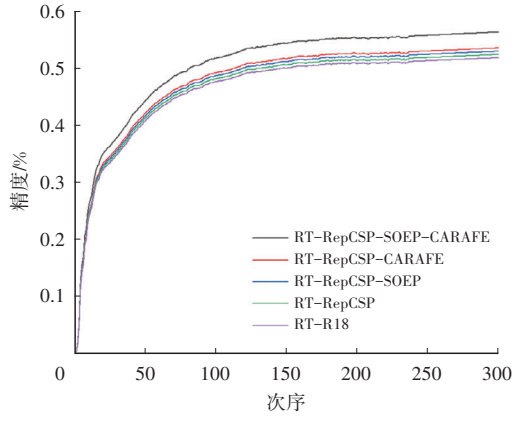


（e）RT-RepCSP-SOEP-CARAFE

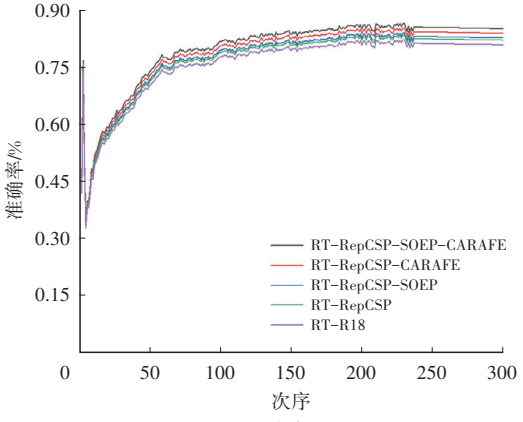
图6　检测效果对比



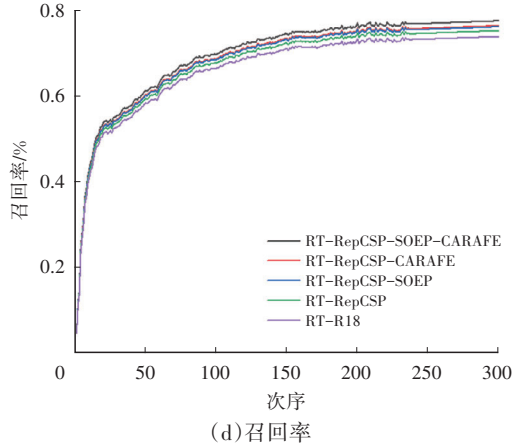
（a）mAP50



（b）mAP50:95



（c）准确率



（d）召回率

图7　改进后的RT-DETR网络效果对比

根据表1的试验数据、图6的可视化结果以及图7的改进效果对比可知，本文提出的RT-RepCSP-SOEP-CARAFE网络在多个方面优于RTDETR-R18、RTDETR-R34、RTDETR-R50，RT-RepCSP-SOEP-CARAFE等模型。具体而言，其所引入的RepCSP模块能够有效抑制背景干扰信息，MSOP模块增强了模型对全局上下文依赖的建模能力，而CAFU模块则在保持检测精度的同时显著提升了推理效率。

此外，RT-RepCSP-SOEP-CARAFE网络基于Transformer解码器实现了端到端的边界框与类别预测，不依赖于预定义锚点机制。相较于依赖CNN结构提取特征并生成锚点的YOLOv8n与YOLOv5m等模型，该网络在精度上表现更优，其多尺度特征融合与全局注意力机制也带来了更稳健的目标检测效果。试验结果表明，改进后的网络在处理密集目标与小尺度目标时具有明显优势，能够有效提升原始模型的检测精度。最终，参数量仅为11.8×10^6个，而mAP50达到87.7%，这一结果充分验证了本文方法在小目标检测场景中的有效性与实用性。

5 结束语

本文提出了一种面向车辆图像的改进RT-DETR检测算法。该算法首先采用RepCSP模块重构主干网络以增强特征提取能力；随后引入SPD与OFI模块，分别强化空域与频域的特征表示；进一步结合Conv卷积、Convec编码卷积及Softmax函数，将动态生成的核权重映射为高分辨率特征图，从而有效解决复杂环境下车辆检测存在的效率低、特征提取弱与精度不足等问题。

试验结果表明，所提算法在mAP50与mAP50:95指标上分别达到87.7%与56.5%，较原始RT-DETR提升6%与4.5%。改进后的RT-RepCSP-SOEP-CARAFE模型在检测精度与推理速度方面均获得优化，综合性能显著提升。然而，实际车辆识别场景中目标分布更为密集、类别更加多样，因此后续研究将聚焦于复杂环境下的多目标检测任务，进一步提升DETR网络在真实场景中的适应能力。

参 考 文 献

[1] CARION N, MASSA F, SYNNAEVE G, et al. End-to-End Object Detection with Transformers[C]// Computer Vision-ECCV 2020, 2020: 213-229.

[2] DONG G, ZHANG Y, XIE W, et al. A Safety Helmet-Wearing Detection Method Based on Cross-Layer Connection[J]. Journal of Real-Time Image Processing, 2024, 21(3): 1-10.

[3] LI J, WANG J. Research on Vehicle and Pedestrian Detection Based on Improved RT-DETR[J]. International Journal of Advanced Network, Monitoring and Controls, 2025, 10(2): 85-93.

[4] WANG Y, XU S, WANG P, et al. Vehicle Detection Algorithm Based on Improved RT-DETR[J]. The Journal of Supercomputing, 2024, 81(1): 290.

[5] CHAI B, NIE X, ZHOU Q, et al. Enhanced Cascade R-CNN for Multiscale Object Detection in Dense Scenes from SAR Images[J]. IEEE Sensors Journal, 2024, 20143-20153.

[6] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Rowards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.

[7] CHEN Z, HE Z, LU M Z. DEA-Net: Single Image Dehazing Based on Detail-Enhanced Convolution and Content-Guided Attention[J]. IEEE Transactions on Image Processing, 2024, 33(2024): 1002-1015.

[8] XIAO Z, LIU Q, TANG G, et al. Elliptic Fourier Transformation-Based Histograms of Oriented Gradients for Rotationally Invariant Object Detection in Remote-Sensing Images[J]. International Journal of Remote Sensing, 2015, 36(2): 618-644.

[9] LONG Y, GONG Y, XIAO Z. et al. Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(5): 2486-2498.

[10] JIANG Z P, WANG Z Q, ZHANG Y S, et al. A Vehicle Object Detection Algorithm in UAV Video Stream Based on Improved Deformable DETR[J]. Computer Engineering and Science, 2024, 46(1): 91-101.

[11] 吴闵奇，杨元华，李航，等. 基于图Transformer和RT-DETR的轻量化水下小目标检测[J]. 计算机应用，2025，11(10)：1-12.
WU M, YANG Y H, LI H, et al. Lightweight Underwater Small Target Detection Based on Graph Transformer and RT-DETR[J]. Computer Applications, 2025, 11(10): 1-12.

[12] 陈仁祥，付铃华，杨黎霞，等. 改进RT-DETR的航拍图像机动车违停检测[J]. 中国惯性技术学报，2025，33(9)：864-870.
CHEN R X, FU L H, YANG L X, et al. Improved RT-DETR for Detecting Illegally Parked Vehicles in Aerial Images[J]. Journal of Inertial Technology of China, 2025, 33(9): 864-870.

[13] 王泽玄，雷雪梅. 基于RT-DETR的轻量化交通标志检测算法[J]. 现代电子技术，2025，48(18)：57-64.
WANG Z X, LEI X M. Lightweight Traffic Sign Detection Algorithm Based on RT-DETR[J]. Modern Electronic Technology, 2025, 48(18): 57-64.

[14] VisDrone2019 YOLO Annotation View[EB/OL]. (2019-10-27) [2025-6-20]. https://www. kaggle. com/code/stpeteishii/visdrone2019-yolo-annotation-view.

[15] 梁秀满，赵恒斌，邵彭娟，等. 基于改进YOLOv5的车辆检测方法[J]. 计算机应用与软件，2025，42(4)：217-222.
LIANG X M，ZHAO H B，SHAO P J，et al. Vehicle Detection Method Based on Improved YOLOv5[J]. Computer Applications and Software，2025，42(4)：217-222.

[16] 任金霞，王金荣，吴吉林，等. 基于YOLOv8复杂环境下车辆行人检测算法研究[J]. 重庆理工大学学报(自然科学)，2025，39(6)：125-131.
REN J X，WANG J R，WU J L，et al. Research on Vehicle and Pedestrian Detection Algorithm in Complex Environments Based on YOLOv8[J]. Journal of Chongqing University of Technology (Natural Science)，2025，39(6)：125-131.

[17] 张志豪，杜丽霞，郝紫微. 多核上下文特征引导下的无人机航拍图像可信检测算法[J]. 北京航空航天大学学报，2024，48(5)：1001-1112.
ZHANG Z H，DU L X，HAO Z W. Reliable Detection Algorithm for Drone Aerial Images Guided by Multi-Core Context Features[J]. Journal of Beihang University，2024. 48(5)：1001-1112.

[18] 王康，王小林，刘心智，等. 基于改进RT-DETR的小目标检测算法[J]. 现代电子技术，2025，48(13)：50-56.
WANG K，WANG X L，LIU X Z，et al. Small Object Detection Algorithm Based on Improved RT-DETR[J]. Modern Electronic Technology，2025，48(13)：50-56.

[19] 田红鹏，李志强，杨赛. 改进RT-DETR的航拍图像小目标检测算法[J]. 计算机工程，2025，11(10)：1-14.
TIAN H P，LI Z Q，YANG S. An Improved RT-DETR Drone Image Small Target Detection Algorithm[J]. Computer Engineering，2025，11(10)：1-14.

（责任编辑　天下溪）

修改稿收到日期为2026年2月26日。

《汽车技术》征稿启事

《汽车技术》杂志是中国第一汽车集团有限公司主办的国内外公开发行的汽车前瞻与应用技术类月刊，为我国高质量科技期刊分级目录入选期刊、中国科学引文数据库（CSCD）来源期刊、中文核心期刊、中国科技核心期刊、RCCSE中国核心学术期刊（A）、Scopus数据库收录期刊、俄罗斯《文摘杂志》（AJ）收录期刊、日本科学技术振兴机构数据库入选期刊、EBSCO学术数据库收录期刊、欧洲学术出版中心（EuroPub）数据库收录期刊。

《汽车技术》杂志以报道汽车整车及其零部件设计、研究、试验等方面的前瞻与应用技术为主，并兼有理论研究内容，是中国汽车行业核心学术和知识传播与共享的平台。

《汽车技术》将在国家提出的“创新、协调、绿色、开放、共享”发展理念的指引下，把握《节能与新能源汽车技术路线图》和“低碳化、信息化、智能化”的汽车技术主流发展趋势，努力在传统内燃机汽车高效动力系统、轻量化、低阻力领域，新能源汽车和互联智能汽车技术领域，大力吸收优质稿源，为广大科研和工程技术人员服务，为我国汽车工程技术创新能力提升贡献力量。

《汽车技术》欢迎高等院校师生、研发工程技术人员、技术管理人员及相关人员不吝赐稿，反映国家重点扶持项目、自然科学基金项目和其他重点项目等研究成果的稿件将被优先选择刊登。

投稿要求：

1. 文章字数最好控制在6 000~8 000字范围之内；

2. 请按科技论文要求撰写文章摘要，摘要中文字数控制在180字左右；

3. 文章必须附有公开发表的、体现本领域最新研究成果的参考文献，且在文中应标注文献引用处；

4. 文章主要作者应提供其简介，包括出生年、性别、职称、学历、研究方向及技术成果等；

5. 来稿的保密审查工作由作者单位负责，确保署名无争议，文责自负；

6. 请勿一稿多投；

7. 本刊使用网站投稿，请先登陆网站注册成功后投稿，详细投稿要求见本刊网站中“下载中心”栏的“作者指南”，网址：http://qcjs.cbpt.cnki.net。

《汽车技术》编辑部