

基于麻雀搜索算法改进的 YOLOv7-ECA-SSA 模型的车辆检测^{*}

陈 红 张 乐

(西安工业大学电子信息工程学院 西安 710021)

摘 要:为解决复杂背景下小目标车辆检测存在的误检、漏检等现象,创新性提出一种改进 YOLOv7 网络的目标检测算法。首先,为解决小目标车辆存在次要信息干扰问题,将高效通道注意力(ECA)机制融于 YOLOv7 模型的主干网络特征层,通过自适应学习来增强目标区域信息权重占比,抑制无关信息;其次,为解决神经网络检测模型训练的超参数随机经验设定性问题,将麻雀搜索算法(SSA)对检测模型训练超参数进行优化,通过内外双循环迭代方式,快速收敛出全局最优学习率,进而得到最优组的权重信息,最终提高小目标车辆检测精度。实验结果表明,基于结构优化、超参数优化的 YOLOv7-ECA-SSA 检测模型在 BDD100K 数据集上的检测精度为 79.01%,比原始模型提高了 5.38%,具备更好的小目标车辆检测性能。

关键词:车辆目标检测;YOLOv7;注意力机制;超参数优化;麻雀搜索算法

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 510

Vehicle detection based on improved YOLOv7-ECA-SSA model with sparrow search algorithm

Chen Hong Zhang Le

(School of Electronic Information Engineering, Xi'an Technological University, Xi'an 710021, China)

Abstract: To solve the small target under complex background of vehicle detection error detection, leak phenomenon, such as innovative put forward an improved YOLOv7 network target detection algorithm. Firstly, in order to solve the problem of small target vehicle secondary information interference, the ECA attention mechanism was integrated into the main network feature layer of YOLOv7 model, and the weight proportion of target area information was enhanced and irrelevant information was suppressed through adaptive learning. Secondly, in order to solve the qualitative problem of hyperparameter stochastic experience of neural network detection model training, the sparrow search algorithm was used to optimize the hyperparameter of detection model training, and the global optimal learning rate was quickly converged through internal and external double loop iteration, and then the weight information of the optimal group was obtained, and finally the detection accuracy of small target vehicles was improved. The experimental results show that the detection accuracy of YOLOv7-ECA-SSA detection model based on structure optimization and hyperparameter optimization is 79.01% on BDD100K data set, 5.38% higher than that of the original model, and has better detection performance of small target vehicles.

Keywords: vehicle target detection; YOLOv7; attention mechanism; hyperparameter optimization; sparrow search algorithm

0 引 言

随着互联网、计算机视觉等技术的发展,自动驾驶技

术成为目前智能交通领域研究的热点^[1-2]。但是自动驾驶环境下的道路情况非常复杂。车辆行驶中易受光照、天气等复杂因素的影响,导致目标特征发生变化,还会出现车

收稿日期:2023-08-29

^{*} 基金项目:陕西省科技厅项目(2023-YBGY-031)资助

辆局部遮挡的情况,从而在目标检测过程中易发生漏检、误检等现象。因此,在复杂道路环境下对车辆进行准确、实时的检测在自动驾驶领域具有着重要的研究价值。

传统的目标检测算法对于道路环境较复杂的自动驾驶来说,操作过程复杂、目标提取困难且检测速度较慢,无法达到对车辆目标进行实时检测的要求。

目前,深度学习^[3]在物体检测方面已经取得了巨大的成功,其优势在于其能够自动提取特征并进行分类,具有较高的准确率和鲁棒性,适用于各种不同领域的检测任务^[4]。分别是 Faster R-CNN^[5] 为代表的双级检测算法(two-stage)和单次多边框检测(single shot multibox detector, SSD)^[6]、YOLO(you only look once)^[7] 网络为代表的单级检测算法(one-stage)。双级检测算法通过增加网络深度来提升检测精度,因此会牺牲检测速度和数据内存。

而单级检测算法不需要提取候选框,只需一次特征提取便可实现目标检测,检测效率大大提升,因此单级检测算法常用于车辆检测。YOLO 算法作为极具代表性的单目标检测算法,2015 年提出 YOLOv1 算法,并不断发展革新。针对小目标车辆误检漏检问题,文献[8]提出在 YOLOv4 算法中设计新的特征融合网络,降低小目标车辆的漏检率,并对损失函数进行改进,最终模型检测精度有所提升,但所改进算法的模型较大,对于车载系统的存储空间和算力要求较高。文献[9]提出将 SimAM(simple attention mechanism)无参注意力机制^[10]与 ACON-C 激活函数结合起来对 YOLOv4 主干网络的残差结构进行改进,在不增加额外参数数量的前提下降低特征损失,从而提高网络性能。文献[11]提出基于 YOLOX 网络的多尺度融合算法。首先改进网络的 CSP(cross stage partial)结构与空间金字塔池化结构(spatial pyramid pooling, SPP)^[12]结构,优化网络的信息传输,提高检测效率,并添加 CA(coordinate attention)注意力机制^[13],增加检测目标的特征表达能力,改善目标漏检问题。文献[9]与文献[10]所使用方法虽对模型检测精度有一定提升,但对检测速度有所牺牲。

因此,针对当前改进算法在复杂交通背景下的目标检测过程中存在检测速度与精度无法平衡的情况,本文基于 YOLOv7^[14] 算法,在模型主干网络部分加入高效通道注意力^[15](efficient channel attention, ECA),提升目标区域的特征提取能力;针对深度学习中的参数优化问题,使用麻雀搜索算法^[16](sparrow search algorithm, SSA)对模型学习率进行迭代优化,快速收敛出最优学习率,在不增加模型复杂度的情况下提高模型检测性能。

1 YOLOv7 模型

YOLOv7 算法集成了现有的 trick,并添加了模块重新参数化和动态标签分配策略,使 YOLOv7 算法在 5~160 fps 推理范围内的检测速度与精度优于所有已知的目

标检测器。

YOLOv7 网络模型包含 3 部分,分别为输入(Input)、主干网络(Backbone)以及头部(Head)。首先,将图片大小调整为 640×640 并进行预处理,之后输入到主干网络中,主干网对图像信息进行特征提取,并经过 Head 模块特征融合,输出 3 层不同大小的特征信息;最终,融合后的特征经过 Rep(重参数化模块)和 1×1 卷积层来输出预测结果。

YOLOv7 的主干网络主要由卷积、E-ELAN 模块和 MPConv 模块构成。E-ELAN 模块可以使网络聚焦于更重要的特征,实现网络学习能力的持续增强。MPConv 模块是被用于提高卷积神经网络训练速度和效率,它通过降低计算精度来减少计算量和内存占用,加快模型的训练速度。

YOLOv7 的 Head 模块与 YOLOv5 相同,仍然采用特征金字塔网络+路径聚合网络(FPN+PAN)结构。仍然采用 FPN+PAN 结构。通过自顶向下和自底向上的特征融合方式,构建具有多尺度感受野的特征金字塔,并使用 PAN 结构对不同分辨率的特征图进行有效的融合,提高特征表达能力,从而实现准确、高效的目标检测。YOLOv7 模型结构如图 1 所示。

2 YOLOv7 模型的改进

2.1 基于通道注意力机制改进的 YOLOv7-ECA 模型优化设计

注意力机制^[17]已广泛应用于大规模检测任务中,可通过捕获上下文的相关性来增强卷积神经网络的性能。常见的注意力机制有通道注意力机制与空间通道注意力机制等。挤压和激励网络(squeeze and excitation network, SE-Net)^[18]通过自适应地学习每个通道的权重,增强神经网络性能,使网络更有效地学习和利用特征通道之间的关系。但 SE-Net 经过全连接层进行降维会给通道注意力预测带来明显副作用。

为了开发更好的性能,有研究提出混合注意力机制,如卷积块注意力机制(convolutional block attention module, CBAM)^[19],即引入通道、空间注意力机制两个维度来提升网络特征提取能力^[20],从而提高模型性能,但同时会使模型趋于复杂化,计算量更大,因此会大大影响模型检测速度。

因此,本文引入一种轻量注意力机制 ECA。此模块是对 SENet 的改进,可避免降低维度对模型性能带来的影响,有效捕获跨通道交互特征,从而提高网络的表示能力和泛化性能。ECA 注意力机制结构如图 2 所示。该模块在每个通道全局平均池化后,通过大小为 k 的快速一维卷积有效地捕获局部跨通道交互,之后将信道信息的权重乘以原始输入特征层得到具有信道关系的特征向量。

2.2 基于 SSA 改进的 YOLOv7-SSA 模型优化设计

学习率是深度学习中重要的超参数之一,学习率的设




图1 YOLOv7 网络结构模型




图2 ECA 注意力机制结构

置会极大影响模型的收敛速度和训练效果。好的学习率不仅会使模型在训练中跳出局部最优,还可以加快模型的收敛速度,提高模型性能。

为解决神经网络检测模型训练的超参数随机经验设定性问题,本文创新性将 SSA 应用于 YOLOv7 网络模型中,对检测模型训练超参数进行优化,通过内外双循环迭代方式,使模型快速收敛出全局最优学习率,进而得到最优组的权重信息,进一步提高模型检测精度。

SSA 是一种新型的仿生优化算法,模拟的是麻雀在觅食时的搜索行为和反捕食行为,通过每代种群中发现者、追随者和警戒者的位置更新变化,逐步找到食物能量最高的位置,即最优解。

SSA 建模过程如下。

设麻雀种群为 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$, n 是麻雀数量, d 维 SSA 个体初始化为 $\mathbf{X}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]$ 。

发现者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right), & R_2 < ST \\ X_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (1)$$

式中: $X_{i,j}^t$ 代表第 i 只麻雀在第 t 次迭代的具体位置; $\text{iter}_{\max}$ 是迭代次数最多的常数;随机数 $\alpha \in [0,1]$, $R_2 \in [0,1]$, $ST \in [0.5,1]$ 分别代表警报阈值与安全阈值; $\mathbf{L}$ 是每个元素均为 1 的矩阵; Q 是一个满足正态分布的随机数。

追随者的位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), & i > n/2 \\ X_{\text{best}}^{t+1} + |X_{i,j}^t - X_{\text{best}}^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L}, & i \leq n/2 \end{cases} \quad (2)$$

式中: X_{best} 代表最优探索者的位置; X_{worst} 代表当前全局最差位置; $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)^{-1}$ 。

当遇到危险时,警戒者的位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{best}}^t|}{(f_i - f_w) + \epsilon}\right), & i > \frac{n}{2} \end{cases} \quad (3)$$

式中: β 是步长控制参数,服从 $[0,1]$ 正态分布; $K \in [-1,1]$; f_i 是麻雀的适应度值; f_g 与 f_w 分别是区域最优、最差的适应度值。最小常数 ϵ 用以避免零除法误差。 $f_i > f_g$ 代表麻雀位于种群的边缘。

麻雀搜索算法的流程如图 3 所示。

3 实验结果与分析

3.1 实验数据集

实验采用 BDD100K 公开驾驶数据集进行实验。本




图3 麻雀搜索算法流程

文选取 car、bus、truck 3 类标签的图片共计 8 074 张进行试验,包含不同天气场景,保证数据多样性。

3.2 实验环境与参数设置

1) 实验环境

网络实验环境如表 1 所示。

表 1 实验环境配置

环境	配置
系统环境	Ubuntu18.04
GPU	RTX3090
CPU	Intel(R) Xeon(R) Platinum 8350C
深度学习框架	PyTorch1.7.0
语言	Python3.8
加速环境	CUDA11.0

2) 实验参数

网络实验参数设置如表 2 所示。

表 2 实验参数设置

参数	数值
weights	YOLOv7. pt
hyp	hyp. scratch. p5. yaml
epochs	61
batch_size	16
workers	8

3.3 评价指标

本文选取以下指标来衡量模型性能,准确率(precision,P)、召回率(recall,R)、帧率以及平均精度均值(mean

average precision,mAP)。

$$P = \frac{TP}{TP + FP} \tag{4}$$

$$R = \frac{TP}{TP + FN} \tag{5}$$

式中:TP 为预测结果为正例(P),实际结果为正确(T);FP 为预测结果为正例(P),实际结果为错误(F);FN 为预测结果为负例(N),实际结果为错误(F)。

3.4 实验结果与分析

1) 基于 ECA 通道注意机制优化的检测模型测试实验

为了验证基于通道注意机制的改进模型的检测效果,将 ECA 注意力机制集成到 YOLOv7 网络模型中,得到 YOLOv7-ECA 模型;并采用表 2 所示实验参数进行训练。当模型训练 61 次左右时,返回的损失值到达收敛状态。模型损失函数变化曲线如图 4 所示。可见,相比 YOLOv7 模型,基于通道注意机制优化的检测模型 YOLOv7-ECA 模型更快收敛,损失值更小,稳定性有一定提升。




图 4 模型损失函数曲线对比

2) 基于 SSA 麻雀搜索算法优化的检测模型测试实验

为了验证基于麻雀搜索算法的改进模型的检测效果,本文将 SSA 模块集成到 YOLOv7-ECA 网络模型中,得到了 YOLOv7-ECA-SSA 模型。并采用表 2 的实验参数进行训练。当模型训练 61 次左右时,返回的损失值到达收敛状态。模型损失函数变化曲线如图 5 所示。可见,相比 YOLOv7 模型与 YOLOv7-ECA 模型,经过麻雀搜索算法优化的 YOLOv7-ECA-SSA 模型更快收敛,且损失值更小,模型更加稳定。因此所改进方法对于模型网络性能提升有着非常重要的意义。




图 5 模型损失函数曲线对比

3)注意力机制模块对比试验

为了验证注意力机制模块对算法改进的有效性,在YOLOv7 算法的基础上加入 CBAM 模块、SimAM 模块以及 ECA 模块进行实验对比。网络模型性能对比如表 3 所示。

表 3 注意力机制模块对比实验

模型	帧率/fps	mAP@0.5/%
YOLOv7	59	73.63
YOLOv7+CBAM	53.46	73.75
YOLOv7+SimAM	61.92	73.10
YOLOv7+ECA	47	74.94

由表 3 可以看出,在 YOLOv7 算法中引入 CBAM 注意力机制后,平均检测精度只提升了 0.12%,且由于其同时关注通道与空间信息,检测帧率降低了 5.54 fps;在 YOLOv7 算法中引入 SimAM 注意力机制后,虽然其检测帧率有所提升,但平均检测精度下降了 0.53%;在 YOLOv7 算法中引入 ECA 注意力机制后,平均检测精度提升了 1.31%,涨幅最大,但检测帧率降低了 12 fps,因此,本文引入的 ECA 注意力机制模块可以有效提升模型的检测精度,但由于模型结构的改变,因此对于检测速度来说有一定影响。

4)消融实验

为了验证上述改进策略的有效性,设计消融实验。所有模型的训练方法、环境配置以及训练参数均一致。以 YOLOv7 作为基准算法,依次在 YOLOv7 的基础上加入 ECA 注意力机制模块、SSA 麻雀搜索算法。消融实验结果如表 4 所示。

表 4 消融实验

模型	帧率//fps	mAP@0.5/%
YOLOv7	59	73.63
YOLOv7+ECA	47	74.94
YOLOv7+SSA	62	77.71
YOLOv7+ECA+SSA	62	79.01

根据实验结果分析得出,引入 ECA 通道注意力机制模块后,虽然该模块本身参数较小,计算量相对较少,但本质上改变了模型结构,因此对模型检测速度有一定影响,其次 YOLOv7-ECA 检测模型的 mAP 为 74.94%,相比原始 YOLOv7 模型精度提高了 1.31%,表明加入 ECA 注意力机制后,模型具有较强的特征提取能力。可见,通道注意力机制通过获取输入特征层和各信道的权重,能够自适

应地关注所需的信道标签信息,从而提高模型的检测精度;在引入 SSA 后,由于该模块改变的是算法本身,不改变模型结构,因此对模型检测速度影响不大,其次 YOLOv7-SSA 检测模型的 mAP 比原算法高 4.08%,说明加入 SSA 模块可以优化模型的学习率;在同时引入两个模块后,YOLOv7-ECA-SSA 模型得到的最优学习率为 0.034 2,最佳检测精度为 79.01%,比 YOLOv7-ECA 模型提高了 4.07%,比原始 YOLOv7 模型提高 5.08%,表明 YOLOv7-ECA-SSA 模型可以优化模型的学习率,使模型能够更快的收敛到最优学习率,进而得到最优组的权重信息,最终提高模型的检测精度。

5)改进的 YOLOv7 网络模型与其他网络模型的对比

本文将优化的 YOLOv7 网络模型与其他网络模型进行实验对比,目的是验证改进网络模型的有效性。本文环境配置及初始训练参数均一致,结果如表 5 所示。

表 5 不同网络模型实验结果对比

模型	帧率/fps	mAP@0.5/%	精度提升 指数 Q
Faster R-CNN	25	57.17	-16.46
YOLOv5	48	72.34	-1.29
YOLOv7	59	73.63	0
YOLOv7-tiny	78	62.73	-10.90
Improved-YOLOv7	62	79.01	5.38

由表 5 实验结果可见,Faster R-CNN 与 YOLOv5 算法的检测精度与检测帧率均低于 YOLOv7 算法;YOLOv7-tiny 算法虽检测帧率最高,但平均检测精度低于 YOLOv7 算法;而 YOLOv7-ECA-SSA 模型检测精度与检测帧率均高于 YOLOv7 算法,具有更好的检测性能,能够满足检测精度与实时性的要求。

改进前后算法的检测效果如图 6 所示,其中包括 3 个场景,图 6(a)~(d)依次为 YOLOv5 算法、YOLOv7 算法、YOLOv7-tiny 算法以及 YOLOv7-ECA-SSA 算法的训练结果。由图 6A 可以看出,改进前的 YOLOv7 算法并没有检测出远处被绿色出租车右侧遮挡的小目标车辆,改进后的算法不仅可以检测出被遮挡车辆,且检测精度均有所提升;由图 6B 可以看出,改进前的 YOLOv7 算法并没有检测出大树与路灯之间被遮挡的小目标车辆,同时 YOLOv5 算法、YOLOv7-tiny 算法漏检了一黄色车辆,改进后的算法不仅检测出所有车辆且检测精度提升;由图 6C 可以看出,改进前的 YOLOv7 算法出现车辆误检,改进后的算法不仅能够准确检测出每一辆车,且检测精度同样有所提高,再次验证了本文改进策略的有效性。



图6 实验检测效果

4 结 论

在车辆小目标的实时检测任务中,由于背景复杂、检测目标小以及特征提取受限等问题,导致检测结果不佳。针对以上问题,提出一种基于 YOLOv7 改进的算法,首先将 ECA 通道注意力机制模块融入 YOLOv7 的主干网络特征层中,用于增强提取特征能力;其次,引入 SSA 麻雀搜索算法对检测模型的学习率进行优化,经过连续迭代得到最优学习率,进一步提高检测精度。在 BDD100K 数据集上进行试验的试验结果表明,改进的 YOLOv7-ECA-SSA 模型相比原始 YOLOv7 算法,检测精度提升了 5.38%,检测速度提升 3 fps;由网络模型对比实验可以看出,改进模型的检测精度优于其他主流目标检测网络。因此,改进后的算法在真实场景检测任务中的性能更好,漏检、误检率有所降低,进一步说明了本文的改进策略具有一定的科学性和实际应用价值。

参 考 文 献

- [1] 贺晓东,王春艳,孙昊,等. 基于局部特征与视点感知的车辆重识别算法[J]. 仪器仪表学报,2022,43(10): 177-184.
- [2] 范宜标,卢玮,傅智河. 自动驾驶场景下的鲁棒车辆检测[J]. 电子测量与仪器学报,2018,32(12):60-65.
- [3] 谷永立,宗欣欣. 基于深度学习的目标检测研究综述[J]. 现代信息科技,2022,6(11):76-81.
- [4] 侯学良,单腾飞,薛靖国. 深度学习的目标检测典型算法及其应用现状分析[J]. 国外电子测量技术,2022,41(6):165-174.
- [5] 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.

- [6] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Proceeding of European Conference on Computer Vision. Berlin: Springer, 2016: 21-37.
- [7] 茅智慧,朱佳利,吴鑫,等. 基于 YOLO 的自动驾驶目标检测研究综述[J]. 计算机工程与应用, 2022, 58(15): 68-77.
- [8] 陈艳菲,晏彰琛,周超,等. 基于改进 YOLOv4 的自动驾驶场景车辆检测[J]. 自动化与仪表, 2023, 38(1): 59-63, 85.
- [9] 刘丽伟,侯德彪,侯阿临,等. 基于 SimAM-YOLOv4 的自动驾驶目标检测算法[J]. 长春工业大学学报, 2022, 43(3): 244-250.
- [10] YANG L X, ZHANG R Y, XIE X H, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. Proceedings of the 3th International Conference on Machine Learning, 2021: 11863-11874.
- [11] 张稀柳,张晓玲,何敏军. 基于改进 YOLOX-s 的车辆检测方法研究[J/OL]. 系统仿真学报, 1-10 [2024-01-18] <https://doi.org/10.16182/j.issn1004731x.joss.22-1106>.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2015, 37(9): 1904-1916.
- [13] XIE C, ZHU H Y, FEI Y Q. Deep coordinate attention network for single image super-resolution[J]. IET Image Processing (S1751-9659), 2021,

- 16(1):273-284.
- [14] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: T-rainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. Computer Science, 2022, DOI:10.48550/arXiv.2207.02696.
- [15] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020:11531-11539.
- [16] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [17] NIU Z Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning [J]. Neurocomputing, 2021, 452:48-62.
- [18] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [19] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [20] 李宇琼, 周永军, 蒋淑霞, 等. 基于注意力机制的交通标志识别[J]. 电子测量技术, 2022, 45(8):116-120.

作者简介

陈红, 副教授, 硕士生导师, 主要研究方向为人工智能、信号与信息处理、计算机视觉与图像处理等。

E-mail: 120268288@qq.com

张乐(通信作者), 硕士研究生, 主要研究方向为人工智能、计算机视觉与图像处理等。

E-mail: 1395928317@qq.com