[文章编号] 1003－4684(2026)04-0127-07

一种基于 ACE-Yolov5 的小目标检测模型

徐久红，吴颖丹，郭依蓓，邵洋琳，李 炎
（湖北工业大学理学院，湖北 武汉 430068）

[摘 要] 小目标的分辨率较低，在复杂的背景下有时难以定位和识别，从而导致漏检和误检的问题，因此小目标检测的精度还有很大的提升空间。为了提升小目标检测精度，一种基于 ACE-Yolov5 的小目标检测模型被提出，在 Yolov5 的基础上引入了小尺度特征地图的专用检测层，融合了上下文使用模块和改进的 ECA 注意力机制。首先，上下文使用模块主要由多分支的空洞卷积层组成，利用不同采样率的空洞卷积多个比例捕捉特征图的上下文信息。第二，将 ECA 进行改进，实现对输入特征图进行通道特征加强，并大大降低参数量。实验结果表明，在 Tsinghua-Tencent100K 数据集和 Traffic Camera Object Detection 数据集上，此 ACE-Yolov5 模型检测性能优于其他模型，与 Yolov5 相比，mAP50 分别提升了 5.1%和 2.2%。

[关键词] 小目标检测；Yolov5；上下文；注意力机制
[中图分类号] TP391 [文献标识码] A

随着大数据发展行动的实施，新一代人工智能的研发应用逐渐加强，“互联网”在体育、教育、文化、医疗等各领域逐步推进。由于目标检测的便利性与优越性，被应用于人脸识别[1]、自动驾驶[2]、医学影像[3]、视频监控[4]等很多军事和民事场景。

目标检测算法的使用效果往往针对大目标较为理想，在小目标的使用上还有很大提升空间。不同学者对目标检测中目标大小定义的标准不同。Chen 等[5]定义当边框面积与图像面积之比的中位数介于 0.08%～0.58%之间时，边框内的实例可以定义为小目标。在 COCO 数据集中，把像素小于 32×32 的目标归为小目标，像素介于 32×32 与 96×96 之间的目标归为中目标，像素大于 96×96 的目标归为大目标。

随着卷积神经网络在深度学习领域的发展，目标检测的网络模型设计逐步向检测精度和速度的平衡方向发展。早期设计的两阶段检测算法 R-CNN[6]，Fast R-CNN[7]，Faster R-CNN[8]，随着网络的优化检测精度大大提升。随后出现了以 SSD[9](Single Shot Multi-box Detector)，Yolo(You Only Look Once)系列[10]为代表的单阶段检测算法，在保证检测精度的同时能提升检测速度。

尽管目标检测在现阶段发展中取得了不错的成果，但是作为目标检测的重难点，小目标检测仍然是一项具有挑战性的任务。首先，小目标比大目标和中目标的分辨率偏低，这使得可以获取到的信息变少，难以提取可以识别的特征。其次，小目标在图像中的位置检测极其容易受到外界环境的影响，对检测框的位置变化敏感，导致对检测网络的定位精度有更高的要求[11]。

1 ACE-Yolov5 介绍

Yolov5 的四种不同的模型分别是：Yolov5s、Yolov5m、Yolov5l、Yolo v5x 型[12]，其中 s 代表 small，m 代表 medium，l 代表 large，x 代表 xlarge，检测速度由快到慢，网络复杂度由简单到复杂。在这四种形式中，它们的网络结构是相同的，由输入、骨干网络、颈部和检测头四部分组成(图 1)。主要区别在于控制网络结构的深度和宽度参数不同，随着深度和宽度参数的逐渐增加，网络的复杂性也随之增加，速度也逐渐变慢。

为了选择合适的基线，在 Traffic Camera Object Detection 数据集上对 Yolov5 系列进行了基础训练实验(表 1)。实验结果表明，Yolov5s 的检测速度表现突出，比检测速度最慢的 Yolov5x 领先 61.392。故选择 Yolov5s 作为基线模型。

[收稿日期] 2024－04－19
[第一作者] 徐久红(1999 －)，女，河北唐山人，湖北工业大学硕士研究生，研究方向为应用统计。
[通信作者] 吴颖丹(1982 －)，女，湖北武汉人，湖北工业大学副教授，研究方向为应用统计。

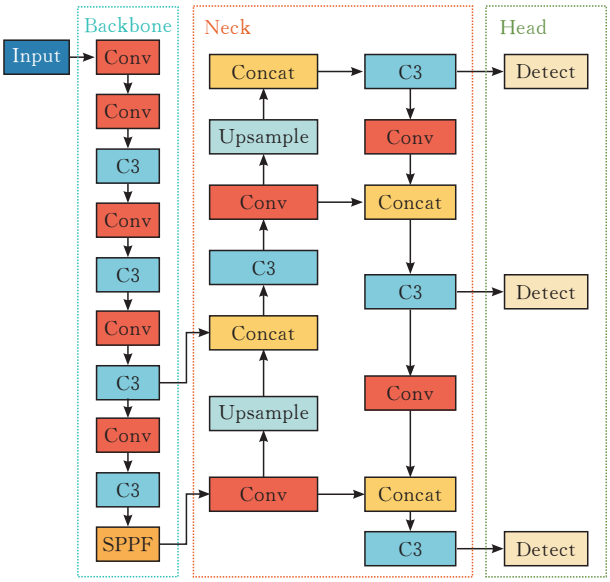

图 1 Yolov5 网络结构

表 1 Yolov5 系列在 Traffic Camera Object Detection 数据集上的表现

基线	FPS
Yolov5s	85.513
Yolov5m	80.192
Yolov5l	38.463
Yolov5x	24.121

使用更高分辨率的特征图通常会提升小目标检测的性能，这种操作与增加输入图像尺寸的方式具有相似的效果[13]。Yolov5 中只有默认的三个检测层，由于小目标的尺寸相对较小，当网络进行较大倍数的下采样时，深层特征难以获取小目标特征信息，针对这一问题，模型中增加了第四个检测层。同时，模型中还加入了 CUM 模块和改进的 ECA，ACE-Yolov5 结构如图 2 所示，C3 和 SPPF 图例解释如图 3 所示。

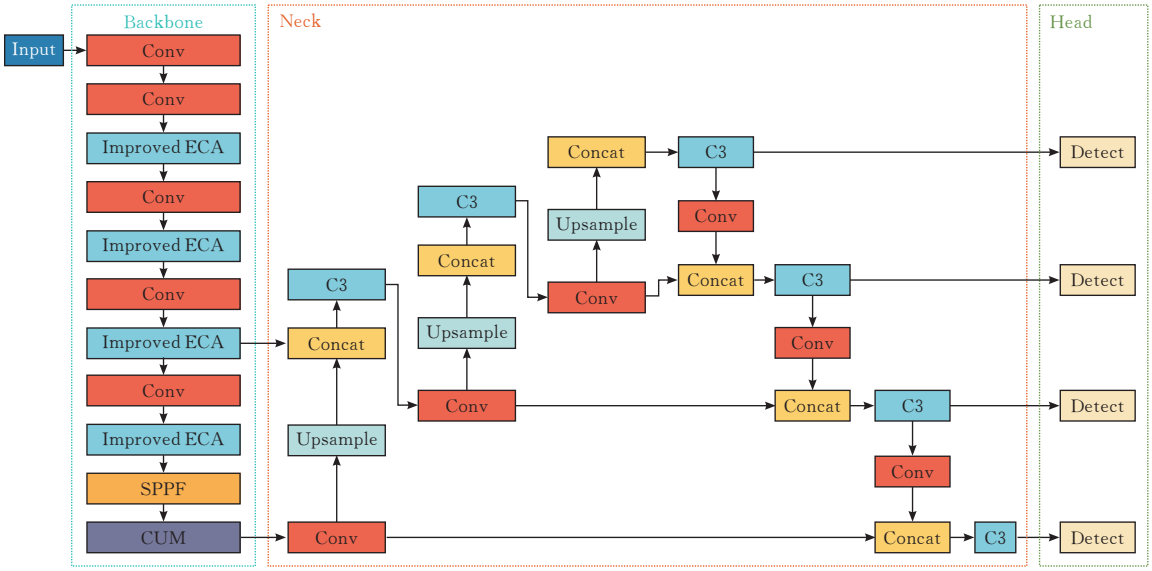

图 2 ACE-Yolov5 网络结构

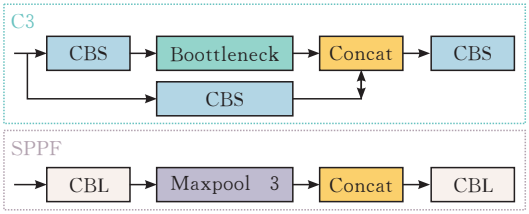

图 3 C3 和 SPPF 结构

1.1 上下文使用模块(CUM)

拥有复杂背景的小目标难以定位和识别，这种情况导致小目标产生漏检和误检的问题，使检测精度低下。然而，在现实世界中，目标与目标之间、目标与背景之间往往存在着相互关联的关系，利用这种关系可以为目标检测提供帮助。CUM 集成来自不同层、不同感受野的上下文信息，有效捕获特征图中的上下文信息。

CUM 结构见图 4，它主要有三个关键组成部分。第一部分为 1×1 卷积操作，降低维数。第二部分为多分支的空洞卷积层，对输入的特征图利用大小为 3×3 的卷积核分别以 1、3、5、7 进行不同采样率的空洞卷积处理并进行采样，特征图的大小 B 利用公式 1 计算，其中 i 表示卷积尺寸，k 表示卷积核大小，s 表示步长，n 表示感受野大小。

$$B = \left[\frac{i + 2p - k - n}{s}\right] + 1 \tag{1}$$

第三部分为池化层，首先对输入的特征图进行自适应均值池化，获取全局特征，然后进行 1×1 卷积操作，对上一层的特征再次提取，并降低维数，最后进行上采样。经过三个部分后，将各层的输出按通道叠加，经过卷积操作恢复至给定的通道数，得到最终输出。

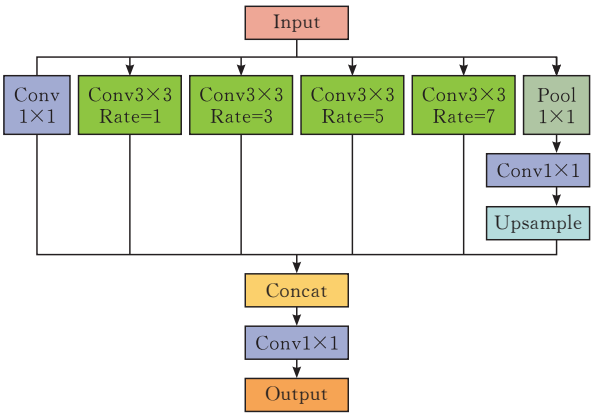

图 4　CUM 的整体结构图

CUM 通过不同采样率对特征图处理，多个比例捕捉特征图的上下文信息，使初始输入图片的粗粒度信息逐渐细化，使得上下文特征被进一步挖掘，充分利用上下文关系，提升深层特征层的表达能力，使小目标更为敏感。

1.2　改进注意力机制 ECA

ECA[26]是一种在 SE[27]基础上进行改进的通道注意力机制，首先对特征图进行压缩，通过全局平均池化 G 将特征图尺寸从(C，H，W)转化为(C，1，1)，其中 C 代表通道数，H 表示特征图的高度，W 代表特征图的宽度。然后利用公式(2)得到自适应卷积核大小，其中 C 代表通道数，$b=1$，$\gamma=2$。采用一维卷积计算通道的权重，整体进行 Sigmoid 激活函数。最后将处理后的权重值与原有特征图进行乘法运算，得到不同权重下的特征(图 5)。

$$k=\left|\frac{log_2(C)}{\gamma}+\frac{b}{\gamma}\right| \tag{2}$$

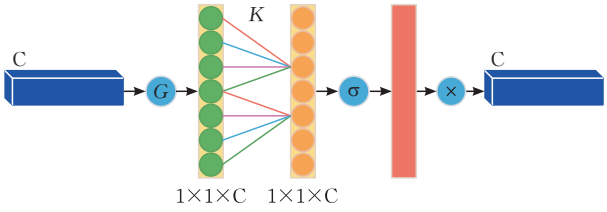

图 5　ECA 结构

为了避免在检测过程中学习通道注意信息时通道维度发生变化，本文将模型中的 C3 模块与 ECA 结合，形成改进后的 ECA，改进后的 ECA 结构如图 6 所示。它实现了输入特征图的通道特征增强，而 ECA 属于轻量级模块，在不改变当前输出特征图大小的情况下，大大减少了参数的数量。它可以专注于捕获检测对象，并帮助神经网络专注于感兴趣的区域。

2　实验

为了评估本文所提出的 ACE-Yolov5 模型在小目标检测方面具有良好的性能，我们将分两个部分进行。首先，将 ACE-Yolov5 模型与最新算法进行多项指标比较。第二，进行消融实验，验证所添加的组件与模型相匹配。

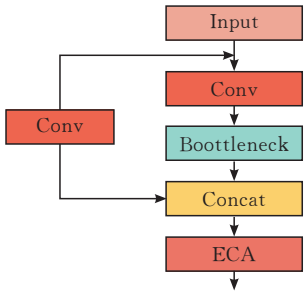

图 6　改进的 ECA 结构

2.1　实验数据集

在本次实验中，所选取的数据集为 Tsinghua-Tencent100K(TT100K)数据集和 Traffic Camera Object Detection(TC)数据集，这两种数据集为小目标检测常用数据集，更能体现实验的目的性。

TC 数据集[14]是来自伊利诺伊州芝加哥市交通摄像头的增强随机屏幕截图的集合，该数据集包含训练集 5248 张图片，测试集 291 张图片，验证集 582 张图片。TT100K 数据集由清华与腾讯的联合实验室整理并公布，是目前中国在交通标识领域最大的公开数据集，提供的 10 万张图像包含了 30000 个交通标志，与先前的交通数据集相比，它拥有更高的分辨率(2048×2048)并且数据量更大。由于 TT100K 数据集中很多类别数量很少，样本不均衡，所以需要针对这一情况进行重新划分。在划分数据集时，只保留图片数超过 100 的类别，统计每个类别的数量后，只保留了 45 类，其中训练集包含 6793 张图片，测试集包含 996 张图片，验证集包含 1949 张图片。

2.2　实验配置细节

实验中所使用的显卡为 NVIDIA GeForce RTX 3060，语言环境及配置分别为 Python-3.7.10，torch-1.10.0，CUDA11.3。输入图片尺寸大小设置为 640×640，使用 SGD 优化器进行训练，将初始学习率设置为 0.01，迭代次数为 200，IOU 阈值设置为 0.5，Batch size 设置为 32，动量为 0.937，权重衰减系数为 0.0005。

在迭代次数设置上，在开始训练时，初步将模型训练 300 次，通过设置更大的训练次数便于观察模型收敛，经过初步试验发现，模型在训练 200 代时已处于收敛状态，所以将模型的迭代次数设置为 200。此次实验研究流程见图 7，首先通过训练计算损失函数并在模型中更新最佳权值，然后使用通过训练获得的最佳权重进行验证和测试过程，最后用得到

的权重预测测试集数据[15]。

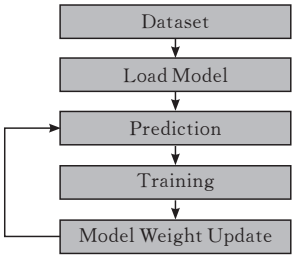

图 7 实验研究流程

2.3 评价指标

实验的评价体系包括精确率(Precision)、回召率(Recall)、mAP50(平均精度)、mAP50-95(平均精度)、F1 等指标。

精确率(Precision)通过表明正确预测结果的比例来衡量模型的准确性。计算公式为:

$$\text{Precision}=\frac{\text{TP}}{(\text{TP}+\text{FP})}\times 100\% \tag{3}$$

召回率(Recall)表示实际为正的样本中被预测为正样本的概率。计算公式为:

$$\text{Recall}=\frac{\text{TP}}{(\text{TP}+\text{FN})}\times 100\% \tag{4}$$

mAP 指的是平均精度， 是所有 AP 值的平均值。mAP50 是指 IoU 0.5 处的平均精度，mAP50-95 评分是将 IoU 阈值(50% ～ 95%)的 mAP 分数取平均值，间隔为 5%。其中 n 表示种类数，计算公式为：

$$\text{mAP}=\frac{\sum_{i=1}^{n}\text{AP}_i}{n} \tag{5}$$

F1 常被用作多分类问题的最终评估方法。计算公式为：

$$F1=2\times\frac{\text{Precision}\times\text{Recall}}{\text{Precision}+\text{Recall}} \tag{6}$$

其中，TP 表示预测结果为正样本，实际结果也为正样本；TN 表示预测结果为负样本，实际结果也为负样本；FP 表示预测结果为正样本，实际结果为负样本；FN 表示预测结果为负样本，实际结果为正样本。

2.4 TC 数据集上实验

为了进一步验证模型的准确性，在 TC 数据集上分别比较了具有代表性的单阶段算法 SSD、Yolov3[16]、Yolov4、Yolov5、Yolov7、Yolov8 的表现，具体细节见表 2。

表 2 各类目标检测模型在 TC 数据集上的性能比较

算法	Precision/%	Recall	mAP50/%	mAP50-95/%	F1
SSD	76.9	0.223	36.6	15.4	0.35
Yolov3	79.9	0.602	63.9	28.3	0.69
Yolov4	73.6	0.573	63.8	22.1	0.64
Yolov5	83.9	0.747	79.9	38.8	0.79
Yolov7	82.5	0.735	79.0	40.0	0.78
Yolov8	81.2	0.662	72.7	37.4	0.73
ACE-Yolov5(ours)	82.5	0.775	82.1	42.5	0.80

如表 2 所示，所提出的算法相比于 Yolov5，仅有模型的精准率(Precision)略有下降，其余指标均有提升。Recall 提升了 0.028，mAP50 提升了 2.2%，mAP50-90 提升了 3.7%。与 SSD、Yolov3、Yolov4、Yolov5、Yolov7、Yolov8 相比，mAP50 分别提升了 45.5%、18.2%、18.3%、2.2%、3.1%、9.4%。在这一指标上均有大幅度的提升，充分体现出改进的模型在检测精度上的优势。

2.5 TT100K 数据集上实验

为更好地说明 ACE-Yolov5 的泛化能力，将 ACE-Yolov5 与 Yolov5 在 TT100K 数据集上也做了比较，比较结果见表 3。观察结果可以发现，ACE-Yolov5 的各类评估指标均有提升，在 mAP50 和 mAP50-90 两项指标进行比较中，Yolov5 模型 mAP50 值为 47.5%，ACE-Yolov5 该项值为52.6%，高出 5.1%。Yolov5 模型 mAP50-95 值为 34.5%，ACE-Yolov5 该项值为 38.6%，高出 4.1%。整体来说，可以看出 ACE-Yolov5 比 Yolov5 模型性能更佳。

表 3 ACE-Yolov5 与 Yolov5 在 TT100K 数据集上的性能比较

算法	Precision/%	Recall	mAP50/%	mAP50-95/%	F1
Yolov5s	64.0	0.454	47.5	34.5	0.39
ACE-Yolov5(ours)	67.6	0.481	52.6	38.6	0.43

为了更为直观地表现 ACE-Yolov5 性能，图 8 为 ACE-Yolov5 检测结果的部分展示。图 8a 展示在 TC 数据集的原图，图 8b 为 Yolov5 的可视化结果，共检测到 13 辆车且最高检测精度为0.84，图 8c 为 ACE-Yolov5 的可视化结果，共检测到 15 辆车且最高检测精度为 0.90。图 8d 展示在 TT100K 数据

集的原图，图 8e 为 Yolov5 的可视化结果，共检测到 4 个路标，最高检测精度为 0.90，并且在 pl5 图标检测为 pl4，出现检测错误情况。图 8f 为 ACE-Yolov5 的可视化结果，共检测到 5 个路标，且最高检测精度为 0.94，未发生误检情况。综合来看，ACE-Yolov5 可以检测到更多小目标，且检测结果更为精确。

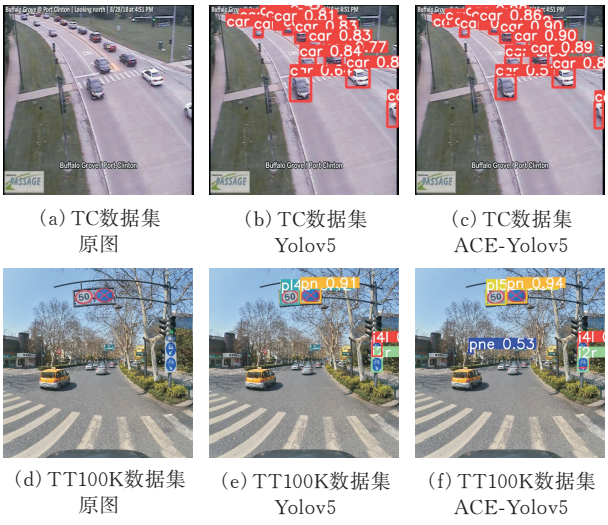

(a) TC数据集原图　(b) TC数据集 Yolov5　(c) TC数据集 ACE-Yolov5

(d) TT100K数据集原图　(e) TT100K数据集 Yolov5　(f) TT100K数据集 ACE-Yolov5

图 8　数据集结果可视化比较

2.6　消融实验

为了说明 CUM 和改进注意力机制 ECA 在模型中的匹配度，在本次实验中采用对比的方式，以剔除注意力机制的 ACE-Yolov5 作为基线，名为 AC-Yolov5，剔除 CUM 的 ACE-Yolov5 作为基线，名为 AE-Yolov5，将比较对象作为唯一变量，结果展示在表 4、表 5。CAM 来自文献[17]，ECA 来自文献[18]，BiFor-mer 来自文献[19]，SimAM 来自文献[20]。

表 4　不同上下文模块的比较

算法	Recall	mAP50/%	mAP50-95/%	F1	FPS/ms
AE-Yolov5＋CAM	0.755	80.1	37.8	0.78	92.53
AE-Yolov5＋CUM	0.775	82.1	42.5	0.80	121.372

从表 4 的结果可以看出，添加本文的 CUM 的模型检测结果在各方面均比其他类型的模块性能优势突出。添加本文的 CUM 的模型在 mAP50 指标达到 82.1%，mAP50 指标达到 42.5%，与添加 CAM 的模型检测效果相比，mAP50 提升了 2%，mAP50-95 提升了 4.7%。在 Recall 和 F1 方面，本文的模型均具有 0.02 的优势。在检测速度上，添加 CAM 的模型检测速度为 92.530，添加 CUM 的模型检测速度为 121.372，比添加 CAM 的模型检测速度高 28.842。综上所述，通过各指标的比较分析，本文提出的 CUM 在检测速度和检测精度上都与模型相匹配，在检测性能上具有突出的优势。

表 5　不同注意力机制的比较

算法	Recall	mAP50/%	mAP50-95/%	F1	FPS/ms
AC-Yolov5＋ECA	0.729	77.4	40.2	0.78	54.271
AC-Yolov5＋BiFormer	0.737	77.5	38.8	0.77	62.659
AC-Yolov5＋SimAM	0.728	77.6	39.1	0.76	75.994
AC-Yolov5＋改进的 ECA	0.775	82.1	42.5	0.80	121.372

从表 5 的结果可以看出，与其他注意机制模型相比，添加改进的 ECA 模型在 Recall 为 0.775，高于最低值为添加 SimAM 模型 0.047。ACE-Yolov5 的 mAP50 为 82.1%，高于最低值为添加 ECA 模型 4.7%。ACE-Yolov5 的 mAP50-95 为 42.5%，高于最低值为添加 BiFormer 模型 3.7%。ACE-Yolov5 的 F1 为 0.80，高于最低值为添加 SimAM 模型 0.04。ACE-Yolov5 的 FPS 为 121.372，高于最低值为添加 ECA 模型 67.101。综上所述，通过各指标的比较分析，本文添加的改进的 ECA 在检测速度和精度上都与模型相匹配。

3　总结

本文研究了一个专注于检测小目标的模型，这一模型在增加第四个检测层基础上，通过不同采样率的空洞卷积获取丰富的上下文信息，同时添加改进的 ECA，提升小目标关注度。为了验证这一目的，选择 TC 数据集和 TT100K 数据集，其中多包含难以检测的小目标，以便于观察效果。实验方法以 Yolov5 作为基线，将本文模型与原有的 Yolov5 模型进行比较，发现本文模型在原有模型性能的基础上多数指标有提升，验证了实验的有效性以及模型的可行性。然后在 TC 数据集将实验结果与 SSD，Yolov3，Yolov4，Yolov5，Yolov7，Yolov8 进行比较，在 mAP50 这一指标上分别提高了 45.5%、18.2%、18.3%、2.2%、3.1%、9.4%。最后进行消融实验，保证每一部分的添加均与模型具有高度适配性。

[参 考 文 献]

[1] Ghenescu V, Mihaescu R E, Carata S V, et al. Face detection and recognition based on general purpose DNN object detector[C]// 2018 International Symposium on Electronics and Telecommunications (ISETC). IEEE, 2018: 1-4.

[2] Dou J, Fang J, Li T, et al. Boosting cnn-based pedestrian detection via 3d lidar fusion in autonomous driving[C]// Image and Graphics: 9th International Conference, ICIG 2017, Shanghai, China, September 13-15, 2017, Revised Selected Papers, Part II 9. Springer International Publishing, 2017: 3-13.

[3] Esmaeilzadeh S, Yang Y, Adeli E. End-to-end Parkinson disease diagnosis using brain MR-images by 3D-CNN[J]. arXiv preprint arXiv:1806.05233, 2018.

[4] Zhang H, Luo C, Wang Q, et al. A novel infrared video surveillance system using deep learning based techniques[J]. Multimedia Tools and Applications, 2018, 77: 26657-26676.

[5] Chen C, Liu M Y, Tuzel O, et al. R-CNN for small object detection[C]// Computer Vision-ACCV 2016: 13th Asian Conference on Computer Vision, Taipei, Taiwan, November 20-24, 2016, Revised Selected Papers, Part V 13. Springer International Publishing, 2017: 214-230.

[6] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.

[7] Girshick R. Fast r-cnn[C]// Proceedings of the IEEE international conference on computer vision, 2015: 1440-1448.

[8] Ren S, He K, Girshick R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems, 2015, 28:1137-1149.

[9] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector[C]// Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14. Springer International Publishing, 2016: 21-37.

[10] Redmon J, Farhadi A. Yolo9000: better, faster, stronger[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 7263-7271.

[11] Xiaolin F, Fan H, Ming Y, et al. Small object detection in remote sensing images based on super-resolution[J]. Pattern Recognition Letters, 2022, 153: 107-112.

[12] Zhu X, Lyu S, Wang X, et al. TPH-Yolov5: Improved Yolov5 based on transformer prediction head for object detection on drone-captured scenarios[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 2778-2788.

[13] Benjumea A, Teeti I, Cuzzolin F, et al. Yolo-Z: Improving small object detection in Yolov5 for autonomous vehicles[J]. arXiv preprint arXiv: 2112.11798, 2021.

[14] Snyder C, Do M. Data for STREETS: A Novel Camera Network Dataset for Traffic Flow[DS]. Urbana-Champaign: University of Illinois at Urbana-Champaign, 2019. https: // doi. org/10. 13012/B2IDB-3671567_V1.

[15] Jung H K, Choi G S. Improved yolov5: Efficient object detection using drone images under various conditions [J]. Applied Sciences, 2022, 12(14): 7255.

[16] Redmon J, Farhadi A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.

[17] Xiao J S, Zhao T, Yao Y T, et al. Context augmentation and feature refinement network for tiny object detection[J]. Journal of Computer Research and Development, 2023, 60(2): 465-474.

[18] Wang Q, Wu B, Zhu P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.

[19] Zhu L, Wang X, Ke Z, et al. Biformer: Vision transformer with bi-level routing attention[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 10323-10333.

[20] Yang L, Zhang R Y, Li L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks[C]// International Conference on Machine Learning. PMLR, 2021: 11863-11874.

A Small Object Detection Model Based on ACE-Yolov5

XU Jiuhong, WU Yingdan, GUO Yibei, SHAO Yanglin, LI Yan

(*School of Science, Hubei Univ. of Tech.,Wuhan* 430068,*China*)

Abstract: Due to the attributes of the small objects, there is still much room for improvement in the positioning accuracy of small object detection. In order to improve the small object detection accuracy, ACE Yolov5 has been proposed based on the Yolov5. We incorporate the Contextual Use Module (CUM) and improved Efficient Channel Attention (ECA) based on the addition of a fourth detection layer in the baseline. First, the CUM mainly consists of a multi-branch null convolution layer, which captures the contex-

tual information of the feature map using multiple scales of null convolution with different sampling rates. Second, the ECA is combined with the C3 module so that the ECA has the C3 attribute, which enables channel feature enhancement of the input feature map and greatly reduces the number of parameters. The experimental results show that, on the Tsinghua Tencent 100K dataset and the Traffic Camera Object Detection dataset, the ACE Yolov5 model proposed in this paper outperforms other models in terms of detection performance. Compared with Yolov5, the mAP50 improved by 5.1% and 2.2%, respectively.
Keywords: small object detection; Yolov5; context; attentional mechanisms

[责任编校: 闫　品]

(上接第 83 页)

A Robust Kernel Density Estimator Based on Window Width Optimization

PENG Bo

(*School of Computer Science, Hubei Univ. of Tech., Wuhan* 430068, *China*)

Abstract: The kernel density estimator, as a non-parametric estimation statistical model, is susceptible to the influence of outlier and window parameter selection when estimating the probability density function of data. In order to improve the accuracy of kernel density estimation under outlier conditions, this study proposes a robust kernel density estimator based on window width optimization. The optimized estimator is implemented in two stages. In the first stage, this study introduces the Levi flight strategy to improve the optimization performance of hybrid rice optimization algorithms. The improved hybrid rice optimization algorithm will be used to optimize the unbiased cross validation objective function and achieve the search for the optimal window value. In the second stage, this study introduces M-robust estimation into the mean calculation process of Hilbert space mapping, reducing the weight of outliers in the probability density function calculation process and eliminating the influence of outliers. Through the optimization of the above two stages, the goal of accurately estimating the probability density function under outlier conditions is ultimately achieved. The experimental results show that when the data contains outliers, the optimized robust kernel density estimator has higher estimation accuracy than traditional kernel density estimators.
Keywords: robust estimation; kernel density estimation; hybrid rice optimization algorithm; Lévy fight; Hibert space

[责任编校: 闫　品]

(上接第 120 页)

Study on Anti-collapse Performance of CFST Frame with Single-sided Bolt End Plates Connection

LI Yutong[1], WANG Donghua[1,2], WANG Haoyu[1], MA Jun[1]

(1 *School of Civil Engineering, Anhui Jianzhu Univ., Hefei*, 230601, *China*;
2 *Prefabricated Building Research Institute of Anhui province, Hefei* 230601, *China*)

Abstract: Based on two typical collapse test models, the accuracy of anti-collapse analysis was verified. A simplified analysis model of half-span beams was proposed to study anti-collapse performance of CFST frame substructures with blind bolt end plates connection. The failure mode, load-displacement curve and resistance mechanism were obtained, and the influence of key parameters is analyzed by numerical simulation. The results show that the structure resistance mechanism is mainly beam mechanism, transition mechanism and catenary mechanism. The ultimate bearing capacity and corresponding displacement of extended end plates are 40.42% and 24.2% higher than flush end plates. The ultimate bearing capacity and corresponding displacement of square CFST substructure are 15.4% and 26.24% higher than circle CFST substructure. The anti-collapse performance of the structure is affected by the key parameters such as bolt diameter, end plate thickness and column thickness. The improvement of bolt diameter for anti-collapse performance and ultimate displacement is most significant.
Keywords: blind bolt; end plate connection; CFST; numerical simulation; anti-collapse performance

[责任编校: 裴　琴]