

小目标场景下基于改进 CNN 网络的图像目标检测研究

陈雪芳¹
CHEN Xuefang

摘要

针对已有方法存在的图像小目标检测精度低、漏检率大等问题,文章提出了小目标场景下基于改进 CNN 网络的图像目标检测研究。为改善传统 CNN 网络模型的缺陷,例如特征丢失、锚框设计失配等缺陷,对 CNN 网络模型进行改进与优化,即在卷积模块添加轻量化卷积堆叠结构,在池化模块添加动态注意力机制,使锚框模块应用自适应锚框技术。将待检测小目标图像输入至训练好的改进 CNN 网络模型中,通过卷积模块获取融合特征图,利用池化模块对特征图进行进一步的处理,突出小目标特征区域,自适应锚框获取小目标预测框,并计算预测框置信度,基于输出模块判定小目标类别,从而实现研究目标。对比实验结果显示:设计方法应用后图像小目标检测结果与图像小目标实际标注情况一致,图像小目标漏检率最小值达到了 0.11%。

关键词

多尺度特征融合增强模块;改进 CNN 网络;动态注意力机制;小目标场景;自适应锚框

doi: 10.3969/j.issn.1672-9528.2025.07.024

0 引言

随着智能感知技术的纵深发展,图像目标检测在复杂场景中的应用边界不断拓展。传统检测框架在通用场景中虽表现稳健,但面对微小目标时召回率骤降逾 40%,暴露出特征表征能力与多尺度适应性不足的固有缺陷^[1]。当前主流 CNN 架构虽通过特征金字塔(FPN)实现多尺度感知,但其层级间特征传递存在高频信息衰减问题^[2]。与此同时,密集背景噪声引发的假阳性率攀升、锚框设计对小目标的先验失配等问题,进一步加剧了检测性能的退化^[3]。尽管已有研究尝试引入注意力机制或超分辨率重建,但往往以牺牲实时性为代价,难以满足工业级部署需求。由此可见,如何设计一种高效的、精准的图像小目标检测方法是现今图像目标检测研究领域的重点课题之一。

近年来,国内外学者针对图像小目标检测方法取得了一定的研究成果,但是由于应用模型、算法或者技术的自身缺陷,无法获得精准的小目标检测结果,制约着相关应用领域的发展。为了解决问题或者缺陷,提出小目标场景下基于改进 CNN 网络的图像目标检测研究。

1 面向小目标检测的改进 CNN 网络设计

CNN 网络模型是当前图像目标检测的主要手段之一,但是在小目标场景应用下,CNN 网络模型存在着较多的问题,例如特征丢失、多尺度适应性不足、背景噪声干扰、锚框设计失配、样本不均衡等,致使其小目标检测精度不足,因此对 CNN 网络模型进行改进与优化,如图 1 所示。




图 1 改进 CNN 网络模型示意图

如图 1 所示,为解决小目标在高层级特征图中信息丢失问题,此研究设计了一种并行多分支结构,在浅层网络中直接提取高分辨率特征^[4]。具体而言,输入图像经过初始卷积层后,分为两条并行路径:一条通过常规卷积堆叠提取语义特征(原有 CNN 网络部分);一条通过轻量化卷积堆叠保留空间细节(改进 CNN 网络部分)。两条路径输出特征通过加权融合方式进行整合,从而完成输入图像特征图的提取,用公式表示为:

$$F_c = \alpha \cdot F_h + (1 - \alpha) \cdot F_l \quad (1)$$

式中: F_c 代表卷积模块输出的特征图; α 代表自适应权重系

1. 闽西职业技术学院 福建龙岩 364021

数,通过可学习参数进行动态调整; F_h 代表高分辨率分支特征,即轻量化卷积堆叠提取的特征; F_l 代表低分辨率分支特征,即常规卷积堆叠提取的特征。

与此同时,为抑制背景噪声对小目标检测的干扰,此研究在池化模块中添加了动态注意力机制(空间-通道联合注意力机制),需要通过通道注意力模块计算各通道的权重分布,并利用空间注意力模块生成空间权重,表达式为:

$$\begin{cases} \omega_1 = \sigma[W_1 \cdot \delta(F_c) + b_1] \\ \omega_2 = \sigma[W_2 \cdot C(F_c) + b_2] \end{cases} \quad (2)$$

式中: ω_1 代表通道注意力系数; $\sigma[\cdot]$ 代表Sigmoid激活函数; W_1 与 b_1 代表通道注意力系数计算的权重矩阵与偏置项; $\delta(\cdot)$ 代表全局平均池化函数; ω_2 代表空间注意力系数; W_2 与 b_2 代表空间注意力系数计算的权重矩阵与偏置项; $C(\cdot)$ 代表卷积操作函数。

以上述计算的通道注意力系数 ω_1 与空间注意力系数 ω_2 为依据,对特征图进行进一步的处理,表达式为:

$$\hat{F}_c = F_c \otimes \omega_1 \otimes \omega_2 \quad (3)$$

式中: $\hat{F}_c$ 代表动态注意力机制处理后的特征图; $\otimes$ 代表逐元素相乘符号。

针对小目标与默认锚框尺寸不匹配的问题,此研究采用K-means++算法对训练集中的目标框进行聚类分析,生成一组适应小目标分布的锚框尺寸^[5]。需要注意的是,在训练样本选取过程中,传统CNN网络模型存在着小目标样本不平衡问题,致使CNN网络模型训练效果不理想。因此,设计方法采用动态困难样本挖掘策略对训练样本进行选择,应用改进损失函数计算每个样本的分类损失,以此为基础,对样本进行降序排列,选择前 K 个困难样本作为训练样本,从而最大限度地提升改进CNN网络模型的整体性能^[6]。改进损失函数与样本损失值计算公式为:

$$\begin{cases} L(p, y) = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \beta v + \chi \cdot \text{IoU}_s \\ L_i = \frac{1}{K} \sum_{i=1}^K L(p_i, y_i) \end{cases} \quad (4)$$

式中: $L(p, y)$ 代表改进损失函数值; p 代表小目标预测框; y 代表小目标真实框;IoU代表原始CNN网络模型损失函数值; $\rho(\cdot)$ 代表欧式距离; b 与 b^{gt} 代表预测框与真实框的中心点; c 代表最小外接矩形的对角线长度; β 代表辅助系数,其取值范围为0~1; v 代表宽高比一致性项; χ 代表小目标权重补偿因子;IoU_s代表小目标对应的IoU值; L_i 代表第 i 个样本对应的损失值; p_i 与 y_i 代表第 i 个样本的小目标预测框与真实框。

以上述选取的训练样本为基础,计算每个目标框的宽高比($r_i = \frac{W_i}{H_i}$),通过K-means++算法优化聚类中心,表达式为:

$$\Gamma(W, H) = \arg \min_C \sum_{i=1}^K \min_{c_j \in C} D(r_i, c_j) \quad (5)$$

式中: $\Gamma(W, H)$ 代表自适应锚框; W 与 H 代表锚框的宽度与高度; C 代表聚类中心集合; $D(r_i, c_j)$ 代表第 i 个目标框宽高比与第 j 个聚类中心的距离度量结果。

上述过程完成了CNN网络模型的改进与优化,并优化了训练样本选择策略与损失函数公式,基于此对改进CNN网络模型进行训练,为后续图像小目标检测的实现提供性能优越的模型支撑。

2 改进CNN网络模型应用

将待检测小目标图像 f 输入至训练好的改进CNN网络模型中,应用初始卷积层对其进行预处理,表达式为:

$$F = \sum \kappa_0[f] + d_0 \quad (6)$$

式中: F 代表初始卷积层输出的特征图; $\kappa_0[\cdot]$ 代表初始卷积层的卷积核函数; d_0 代表初始卷积层输出通道的偏置项。

利用常规卷积堆叠结构与轻量化卷积堆叠结构提取特征的语义特征与空间特征,表达式为:

$$\begin{cases} F_l = \sum \kappa_l[F] + d_l \\ F_h = \sum \kappa_h[F] + d_h \end{cases} \quad (7)$$

式中: $\kappa_l[\cdot]$ 代表常规卷积堆叠结构的卷积核函数; d_l 代表常规卷积堆叠结构输出通道的偏置项; $\kappa_h[\cdot]$ 代表轻量化卷积堆叠结构的卷积核函数; d_h 代表轻量化卷积堆叠结构输出通道的偏置项。

基于式(1)~(3)对特征图进行进一步的融合与池化处理,获取待检测小目标图像的最终特征图 $\hat{F}_c$,应用式(5)确定的自适应锚框 $\Gamma(W, H)$ 对图像小目标进行检测,以此来获取小目标预测框^[7],表达式为

$$p(f) = \frac{\hat{F}_c \otimes \Gamma(W, H)}{\lambda_0} \quad (8)$$

式中: $p(f)$ 代表待检测图像 f 中的小目标预测框; λ_0 代表小目标预测框的标准化因子。

全连接层采用Softmax函数计算小目标预测框的置信度,以此来判定小目标预测框是否精准^[8],表达式为:

$$O[p(f)] = \hat{W} \cdot p(f) + \hat{b} \quad (9)$$

式中: $O[p(f)]$ 代表小目标预测框 $p(f)$ 的置信度; $\hat{W}$ 与 $\hat{b}$ 代表全连接层的权重矩阵与偏置项。

输出层以全连接层输出结果 $O[p(f)]$ 为基础,将其与阈值 O^e 进行比较^[9]。当 $O[p(f)]$ 大于阈值 O^e 时,认为小目标预测框精准度合格,此时输出小目标预测框 $p(f)$,其即为图像小目标检测结果;当 $O[p(f)]$ 小于或者等于阈值 O^e 时,认为小目标预测框精准度不合格,需要转置初始卷积层进行重新迭代运算,直至满足 $O[p(f)] > O^e$ 条件为止^[10]。与此同时,通过嵌入在输出层中的SVM模型对预测框中的小目标类别进行判定与输出,表达式为:

$$z=\xi[\varphi^T\cdot p(f)+B^e]\tag{10}$$

式中： z 代表预测框中小目标的类别编号； $\xi[\cdot]$ 代表 SVM 函数； φ 与 B^e 代表 SVM 模型的关键参数，分别为超平面法向量与偏置项。

综上所述，在 CNN 网络模型的改进及其应用下，实现了小目标场景下图像目标的有效检测，为相关研究提供一定的支撑与帮助。

3 设计方法应用性能测试

3.1 实验数据集构建

从公共数据集、网络图片、实验拍摄等来源收集包含小目标的图像，以此来确保收集的图像具有多样性，涵盖不同的场景、光照条件、目标姿态等。与此同时，使用 LabelImg 对收集图像进行标注，即小目标真实框、类别等信息，将标注信息保存为标准的 JSON 文件。为了保障实验数据的统一性，对标注后的图像进行预处理，例如尺寸调整、归一化等，以适应检测模型的输入要求。由于研究篇幅的限制，不对图像预处理过程进行过多的赘述。此外，还需要注意的是，在实验数据集构建完整后，需要对数据集进行质量检查，确保标注信息准确无误，并检查图像中的小目标是否清晰可辨，避免模糊或遮挡严重的情况。构建实验数据集情况具体如表 1 所示。

表 1 实验数据集信息表

信息名称	数值配置	单位描述
数据集大小	25.12	GB
图像数量	27 845	幅
小目标类别数量	54	个
训练集大小	19 491	幅
验证集大小	5 569	幅
测试集大小	2 785	幅

3.2 对比实验

选取基于空洞卷积融合 Transformer 的图像小目标检测方法 与 基于改进 YOLOv8 的图像小目标检测方法作为对照方法，将其记为方法 1 与方法 2，联合设计方法共同进行图像小目标检测对比实验，通过实验数据来分析设计方法的应用性能。

3.2.1 小目标检测效果对比

应用本文方法、传统方法 1 与传统方法 2 对任意一幅实验图像进行小目标检测，如图 2 所示。




图 2 图像小目标检测结果示意图

图 2 中小目标类别统一，均为车辆，因此不对其进行额外标注。设计方法应用后图像小目标检测结果与图像小目标实际标注情况一致，而方法 1 与方法 2 应用后图像小目标检测结果与图像小目标实际标注情况具有一定的偏差，存在着小目标漏检的情况。由此可见，设计方法图像小目标检测性能更佳。

3.2.2 漏检率统计分析

3.2.1 节针对单一实验图像进行测试，使得实验结论可信度不高，因此在实验数据集中随机抽取 15 个实验组别，每组要求图像数量在 5 000~10 000 幅范围内。应用设计方法、方法 1 与方法 2 对图像小目标进行检测，并计算小目标漏检率（平均数值），如表 2 所示。

表 2 图像小目标漏检率示意表

单位：%			
实验组别	设计方法	方法 1	方法 2
1	2.13	10.23	12.45
2	3.12	8.59	13.45
3	4.15	7.33	15.02
4	2.01	8.45	10.02
5	1.56	12.15	10.78
6	0.23	11.01	9.45
7	0.11	10.25	8.02
8	2.01	10.45	7.45
9	2.48	9.56	9.23
10	1.45	9.78	9.44
11	1.11	9.25	8.52
12	1.74	8.12	8.55
13	1.41	7.45	9.50
14	1.68	6.12	11.02
15	1.25	5.23	12.45

在不同实验组别背景下，相较于方法 1 与方法 2，设计方法应用后图像小目标漏检率显著较低，最小值达到了 0.11%。这主要是因为设计方法对 CNN 网络模型进行了改进与优化，从而有效提升了模型的应用性能。其中，在卷积模块创新性地结合了常规卷积堆叠与轻量级卷积堆叠。常规卷积堆叠用于提取图像中的语义特征，而轻量级卷积堆叠则提取图像的空间特征，使得模型在保持高检测精度的同时，能够更高效地进行特征提取；在池化模块引入了动态注意力机制，其能够自适应地调整权重，关注图像中的重要区域，尤其是包含小目标的区域，不仅提高了模型的泛化能力，还显著增强了模型对小目标的敏感度；在锚框模块采用自适应锚框技术，其能够根据输入图像中的小目标尺寸和分布情况进行动态调整，从而更加准确地检测到小目标。综上所述，设计方法中改进 CNN 网络模型通过各个模块的协同优化，共同实现了对图像小目标漏检率的显著降低。

4 结语

图像小目标检测在现代计算机视觉领域中占据着举足轻重的地位,不仅推动了技术的革新,还深刻影响了众多实际应用场景。具体来说,图像小目标检测不仅在技术层面推动了人工智能的发展,更在公共安全、工业生产、生态保护、医疗健康等多个领域展现出了不可估量的价值。随着技术的不断成熟和应用场景的持续拓展,其必要性将愈发凸显,成为连接数字世界与现实世界的桥梁,引领未来智能化社会的发展趋势。但已有方法由于应用模型的性能缺陷,无法满足计算机视觉领域的发展需求,故提出小目标场景下基于改进 CNN 网络的图像目标检测研究。通过测试结果可知:设计方法有效提升了图像小目标检测性能,降低了图像小目标漏检率,能够为相关研究提供一定的借鉴与参考。

参考文献:

- [1] 蒋心璐,陈天恩,王聪,等.大田环境下的农业害虫图像小目标检测算法[J].计算机工程,2024,50(1):232-241.
- [2] 王林,刘景亮,王无为.基于空洞卷积融合 Transformer 的无人机图像小目标检测方法[J].计算机应用,2024,44(11):3595-3602.
- [3] 李云文,冯宇平,安文志,等.基于改进 YOLOv8 的无人机图像小目标检测算法[J].高技术通讯,2024,34(7):765-

775.

- [4] 刘赏,周煜炜,代尧,等.融合注意力和上下文信息的遥感图像小目标检测算法[J].计算机应用,2025,45(1):292-300.
- [5] 徐雪峰,郭广伟,黄余.改进全卷积神经网络的遥感图像小目标检测[J].机械设计与制造,2024(10):38-42.
- [6] 张智,易华挥,郑锦.聚焦小目标的航拍图像目标检测算法[J].电子学报,2023,51(4):944-955.
- [7] 张佳敏,闫科,王一非,等.基于改进 Mask-RCNN 算法的作物害虫分类识别[J].农业工程学报,2024,40(7):202-209.
- [8] 马丽娟,黄勇,李艳翠.基于机器学习的低信噪比图像序列小目标检测[J].计算机仿真,2023,40(10):219-223.
- [9] 王坤,丁麒麟.利用自适应融合和混合锚检测器的遥感图像小目标检测算法[J].电子与信息学报,2024,46(7):2942-2951.
- [10] 严春满,王铖.基于特征增强的 SAR 图像舰船小目标检测算法[J].控制与决策,2023,38(1):239-247.

【作者简介】

陈雪芳(1970—),女,福建永定人,本科,高级实验师,研究方向:信息技术应用。

(收稿日期:2025-02-14 修回日期:2025-06-27)

(上接第 104 页)

本文所提算法的精确率达到 98.3%,在与其他机器学习算法的比较中表现最优,且误报率为 2.63%,优于大多数算法。

4 结语

本文的异常流量检测方法结合特征工程与机器学习算法,实现对高维流量数据的高效特征提取,加快了检测效率与精确率。首先基于随机降采样算法对原始数据平衡少数类,然后利用主成分分析算法进行特征降维,得到新的特征子集,将新特征子集作为 LGBM 模型的输入,从而简化机器学习模型训练。使用网格搜索法对 LGBM 进行超参数寻优,最后将改进的 LGBM 模型用于异常流量检测的分类评估。研究结果表明,本文模型优于对比算法,显著提高了精确率,且误报率低于大多数现有模型,所提模型具有高鲁棒性。未来需要探索其他特征工程与数据预处理方法结合的方法来提高检测性能,设计新的检测算法,如深度学习、集成算法等。

参考文献:

- [1] 董丽莎,李胜利,扈宁.计算机网络安全现状及技术应对策略探讨[J].通讯世界,2024,31(8):31-33.
- [2] 吴迪锋,孙昊翔,曹浪,等.网络流量异常检测综述[J].信

息安全与通信保密,2022(8):101-111.

- [3] 张茜,王晓菲,王亚洲,等.基于机器学习的网络入侵检测技术综述[J].网络安全与数据治理,2024,43(12):1-9.
- [4] 罗晓璐,陈鑫,卢微.机器学习在网络入侵检测系统中的应用与效能分析[J].网络安全技术与应用,2024(12):10-12.
- [5] KURNIABUDI, STIAWAN D, DARMAWIJOYO, et al. CIC-IDS-2017 dataset feature analysis with information gain for anomaly detection[J]. IEEE access, 2020, 8: 132911-132921.
- [6] GORYUNOV M N, MATSKEVICH A G, RYBOLOVLEV D. Synthesis of a machine learning model for detecting computer attacks based on the CICIDS2017 dataset[J]. Proceedings of the institute for system programming of RAS, 2020, 32(5):81-94.
- [7] 张阳,姚原岗.基于 Xgboost 算法的网络入侵检测研究[J].信息网络安全,2018(9):102-105.

【作者简介】

王小强(2000—),男,山西兴县人,硕士研究生,研究方向:网络安全, email: isacc10093@163.com。

(收稿日期:2025-03-06 修回日期:2025-07-03)