

基于改进 YOLOv5s 的充电站内车辆起火检测*

阿斯卡尔·艾山¹ 高瑞¹ 马智轲¹ 孙清振¹ 刘凯波² 杨春萍²

(1. 国网新疆电力有限公司博尔塔拉供电公司 博乐 833400; 2. 华北电力大学电气与电子工程学院 北京 102206)

摘要:针对目前对于充电站内车辆起火现象的检测精度较低、检测速度慢等问题,从实用化角度出发,提出了一种基于 YOLOv5s 改进的车辆起火检测方法 YOLOv5s-Fast。首先在 Backbone 网络中采用了全局上下文注意力机制与 C3 模块进行融合,成为一种新的特征提取的模块 C3GC,增强模型提取特征的能力,减少了计算量;其次在 Neck 网络中采用了轻量级上采样算子,能够根据输入图像进行自适应的上采样,提升了检测精度;最后引入解耦头,提高了目标检测的准确率与效率。实验结果表明,所提出的方法 YOLOv5s-Fast 与原 YOLOv5s 相比,平均精度提升了 4.9%、检测帧率由原先的 46 fps 提高到 59 fps,方法更加实用化。

关键词:YOLOv5s;C3GC;轻量级算子;解耦头

中图分类号: TP391.4; TN919.82 **文献标识码:**A **国家标准学科分类代码:** 520.2060

Vehicle fire detection in charging stations based on improved YOLOv5s

Askar Aishan¹ Gao Rui¹ Ma Zhike¹ Sun Qingzhen¹ Liu Kaibo² Yang Chunping²

(1. State Grid Xinjiang Electric Power Co. Ltd., Bortala Power Supply Company, Bole 833400, China;

2. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: In response to the current problems of low detection accuracy and slow detection speed of vehicle fires in charging stations, this paper proposes a vehicle fire detection method YOLOv5s-Fast based on YOLOv5s improvement from a practical perspective. This article first uses the global context attention mechanism and C3 module to fuse in the Backbone network, becoming a new feature extraction module C3GC, enhancing the model's ability to extract features and reducing computational complexity. Secondly, in the Neck network, this paper adopts a lightweight upsampling operator that can adaptively upsample based on the input image, improving detection accuracy. Finally, this article introduces a decoupling head to improve the accuracy and efficiency of object detection. The experimental results show that the proposed method YOLOv5s-Fast has an average accuracy improvement of 4.9% and frame rate increase from 46 fps to 59 fps compared to the original YOLOv5s, making the method more practical.

Keywords: YOLOv5s; C3GC; lightweight operators; decoupling head

0 引言

电车作为一种环保、节能的交通工具,对于减少对化石燃料的依赖和降低温室气体的排放具有重要意义。随着电车的不断普及,充电站作为其电能补给的重要设施,至 2023 年底,为满足电车的充电需求,中国充电基础设施累计建设 859.6 万台。随着充电设施规模的不断扩大,其安全性问题也越来越受到重视。

近年来,车辆充电起火事故层出不穷,对人员生命健康和财产安全构成了严重威胁,同时也影响着充电设施的正常运营。电车起火主要有以下两点原因^[1]:1)由于电车电池热失控^[2]导致车辆起火。电池热失控是指电池在使用过程中因为热量过高、充电过度或者短路等原因导致其内部温度迅速攀升,并最终引起失控,这种情况可能导致电车电池发生爆炸、起火等事故;2)充电桩质量问题^[3]导致车辆起火,由于国内充电桩质量参差不齐,充电桩线路

收稿日期:2024-09-02

* 基金项目:国网新疆电力有限公司科技项目(5230BJ230003)资助

老化、没有过充保护、传感器失灵等问题也会导致充电车辆的起火。因此,开发一种高效、准确的车辆起火检测系统,对于预防和及时响应此类事件至关重要。

虽然火焰和烟雾是火灾发生后所出现的特征,但在起火初期阶段,火焰和烟雾的出现是最为显著的信号。即使不能完全实现早期预警,这些特征的快速检测仍然可以有效减少火灾扩散带来的损失。特别是在充电站这种易燃物较多、空间相对封闭的环境中,火焰和烟雾的快速检测对于及时灭火和疏散人员具有极高的实际意义。

随着近年来计算机视觉技术^[4]的不断进步,各种目标检测算法^[5-7]也广泛应用于火灾监测。文献[8]将YOLOv3原特征提取网络Darknet-53替换为DenseNet,同时将DenseNet中的下采样改为空洞卷积,自动提取火焰特征并实现多尺度的火焰检测。文献[9]针对火焰烟雾检测,提出了改进的YOLOv7目标检测算法,引入GhostNetV2模块、降低参数数量的同时,增加模型检测的准确性,并使用一次性聚合方法来设计跨级部分网络VoV-GSCSP模块降低了计算量和网络结构的复杂性,提升了检测速度,基本满足火焰烟雾实时性的需求。文献[10]通过引入MobileViT轻量化网络来替换YOLOv8中的骨干提取网络,很好地满足了对于火灾实时检测的要求。文献[11]针对火灾检测速度慢、误检率高的问题,提出了一种基于YOLOv5s的实时火焰检测算法,采用K-means重新计算锚框尺寸,同时引入了卷积块注意力机制(convolutional block attention module, CBAM)模块和梯度均衡机制,分别通过特征提取网络和损失函数提升模型的性能。

现有火灾检测方法虽在一定程度上提高了检测的精度和速度,但仍存在明显的不足。双阶段目标检测方法如Faster R-CNN算法由于计算复杂,无法满足实时检测需求;而YOLOv3、YOLOv4等单阶段检测算法在处理小目标和复杂背景时的精度不够,尤其在充电站内高密度充电设施的场景中,可能会错过关键的火灾信号。虽然一些最新的YOLO版本如YOLOv7和YOLOv8在精度上有所提升,但其对计算资源的依赖性过高,限制了在实际场景中的应用。这些问题限制了现有技术在实际充电站场景中的应用^[12]。

为此,本文提出了一种改进YOLOv5s的充电站内车辆起火检测的方法YOLOv5s-Fast。首先在骨干网络(backbone)中引入全局上下文注意力机制与C3模块进行融合成一种新的C3GC模块,该模块能够在保持模型轻量化的同时,增强特征提取能力,并解决了网络在处理复杂背景时的精度问题。其次在颈部网络(neck)中采用了轻量级上采样算子,以替代YOLOv5s中的最近邻插值法。该改进提高了模型在小目标和复杂背景下的检测精度,并降低了由于上采样过程中信息丢失导致的误检问题,提升了检测精度。最后本文引入解耦头,分类与回归任务解耦,有效提高了检测任务的精度和速度,特别是在处理不同尺寸目标时,其表现显著优于传统的耦合头设计,提高

了检测效率,使模型更加实用化。

1 YOLOv5s 网络结构

YOLOv5算法是现阶段比较流行的单阶段目标检测算法,其中YOLOv5s模型最小、检测速度最快,适合处理实时性要求较高的任务。

YOLOv5s的网络结构主要包括骨干网络、颈部网络、头部网络(head)3部分,如图1所示。

骨干网络部分主要包括卷积模块Conv、C3模块与快速空间金字塔池化模块(spatial pyramid pooling fast, SPPF)。卷积模块主要是由卷积层、归一化层、激活函数三者构成,其功能是进行目标特征的提取;C3模块是YOLOv5s算法中一种特有的模块,是通过残差学习与Concat方式来进行主要特征提取的模块,SPPF模块是在空间金字塔池化模块(spatial pyramid pooling, SPP)之上改进而来,它通过使用多个小池化核来替换SPP模块的单个大池化核,提高了检测速度并且能够在劣化过程中更完整地保留目标的多尺度信息,优化了多尺度目标的特征捕捉。

颈部网络采用特征金字塔网络(feature pyramid networks, FPN)结构,并通过PANet结构的补充,强化了特征融合和定位信息传递。

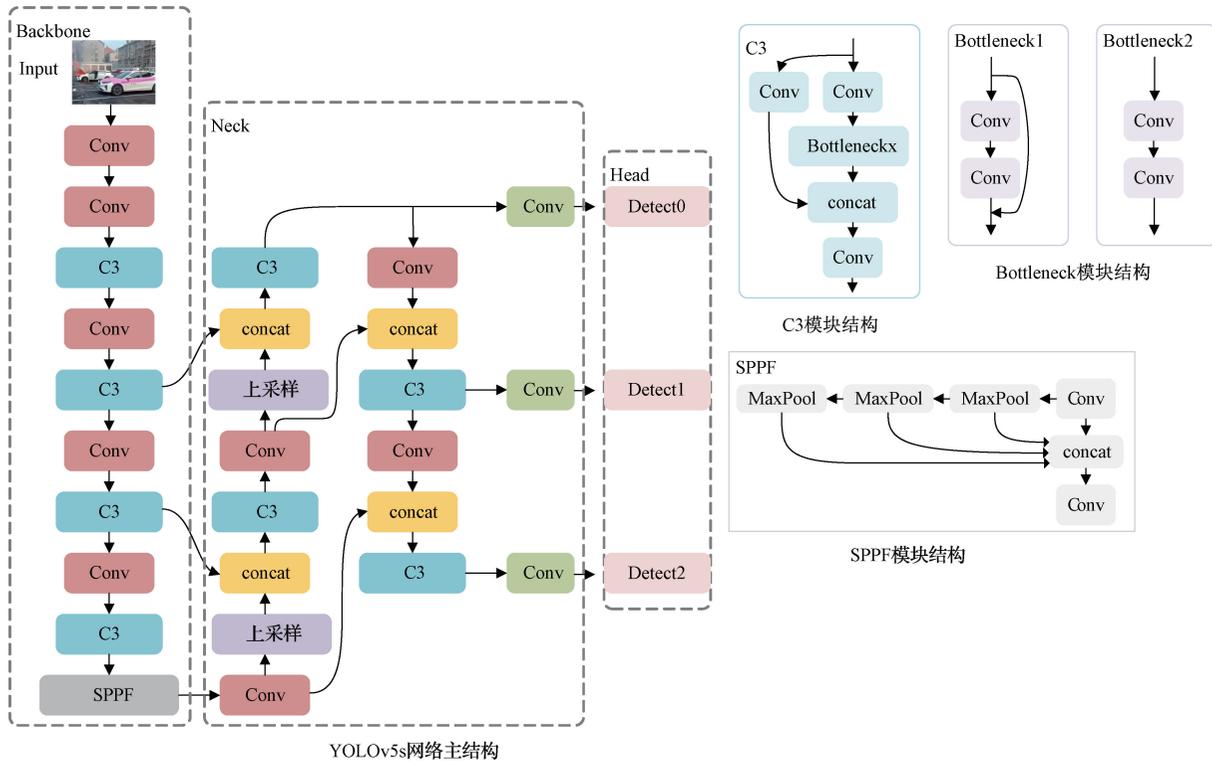
头部网络负责生成检测框,并对它们进行分类、定位和置信度评分。

2 YOLOv5s 算法改进

2.1 引入全局上下文注意力机制(GC)

全局上下文注意力机制来源于GC Net^[13],GC块是在非局部网络的基础上改进而来。通过实验证明,捕获远距离依赖有益于各种识别任务,而在传统的神经网络中,远距离依赖只能通过不断堆叠卷积层来进行建模,该方法效率低下且计算量大。基于此原因,提出了效果更好的GC块。GC块的网络结构如图2所示,GC块可以有效建模图像中的远距离依赖关系,特别是在复杂的火灾场景中,车辆的起火、烟雾等特征并不总是局部清晰,因此首先通过 1×1 卷积块和Softmax模块计算得出图像的注意力权重特征信息,然后与输入的 $H \times W \times C$ 计算得出 $C \times 1 \times 1$ 的全局特征关系信息,有助于提取更全面的图像特征,从而提升检测精度;之后通过Transform结构中的两个 1×1 卷积块来降低模型参数量,节约计算开销,而且在两个 1×1 卷积块之间插入LayerNorm模块,从而提高模型的训练稳定性,并且具有一定的正则化作用,减少模型过拟合的风险;最后将初始信息 $H \times W \times C$ 与全局特征关系信息 $C \times 1 \times 1$ 相加得到强化后图像全局重要信息的输出结果。

本文所提出的新模块C3GC与现有的C3模块对比如图3所示。在Backbone部分,随着网络层数的递增,C3模块在提取浅层次特征时面临挑战,且易于在网络深度增



YOLOv5s网络主结构

图1 YOLOv5s 网络结构

Fig.1 YOLOv5s network structure diagram

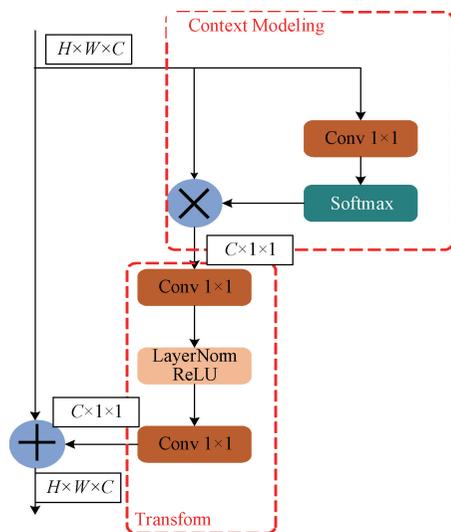


图2 GC块网络结构示意图

Fig.2 Schematic diagram of GC block network structure

加时遭遇梯度消失的问题。所以,本文在两个 Conv 模块之前巧妙地嵌入了 GC 块,该 GC 块通过全局建模关系,有效地促进了模型在 Conv 模块前对全局上下文特征的提取能力,进而提升了模型的精确度,并实现了计算开销的降低。新模块 C3GC 不仅减少了计算量,同时通过全局上下文的建模提升了特征提取能力。相比于单独使用 C3 模

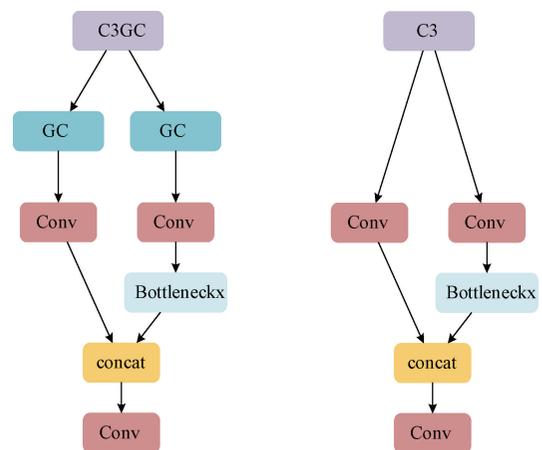


图3 C3GC 与 C3 网络结构对比

Fig.3 Comparison of C3GC and C3 network structures

块,C3GC 模块能够更好地处理复杂场景下的火焰和烟雾检测任务,实验表明,平均精度均值(mAP)明显提升。

2.2 更换轻量级上采样算子

在 YOLOv5s 算法中,Neck 部分主要是针对 Backbone 提取到的高层次特征信息进行特征放大及融合,之所以会有上采样这一操作,目的是将图像恢复到原先的尺寸,在网络深度加深时,模型尽可能地保留信息。在 YOLOv5s 中,上采样采用的方法是最近邻插值法,其思路

是通过相邻像素点的灰度值作为新生成像素点的灰度值,这种方法的缺点在于图像容易出现信息丢失与锯齿状的边缘,造成精度下降的问题。因此本文加入新的轻量级上采样算子^[14-15](content-aware reassembly feature extraction, CARAFE)来替换 YOLOv5s 中的上采样方式,以提高模型特征融合的能力。

CARAFE 是一种上采样运算符,它的核心思想是通过学习像素间的关系进行采样,利用上下文特征关系对低分辨率特征图进行重构,通过对周围像素进行加权融合,生成更高质量的上采样结果,从而获得了丰富的上下文特征,这对于火灾检测中特征较小或较模糊的烟雾和火焰检测具有显著效果。CARAFE 算子与 YOLOv5s 中采用的邻近插值法相比,首先是比邻近插值法具有了更大的感受野,能够获取更多的上下文信息,从而改善特征图的细节恢复,提高检测精度,这对于火灾检测中特征较小或较模糊的烟雾和火焰检测具有显著效果;其次是 CARAFE 只占用很少的计算开销,并且可以集成到主流的几种网络架构中,这使得 CARAFE 成为一个轻量级且高效的算子,适用于计算资源有限的场景。

CARAFE 的特征融合结构如图 4 所示,该算子的实现方式是将输入特征图分解为两个部分,分别是低分辨率特征图和高分辨率特征图。然后,通过学习像素之间的关系,将低分辨率特征图上采样到与高分辨率特征图相同的尺寸。最终,将上采样后的特征图与高分辨率特征图进行融合,得到最终的上采样结果。这一方法有助于提高采样的质量和保真度,适用于需要更高质量图像处理的任务。

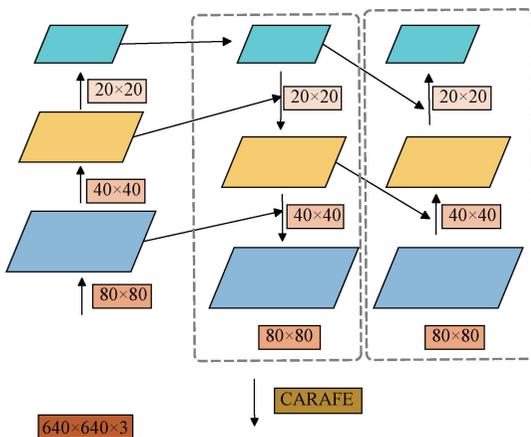


图 4 CARAFE 特征融合结构

Fig. 4 CARAFE feature fusion structure diagram

2.3 更换解耦头

YOLOv5s 的 Head 网络采用的是耦合头的设计,其实质是一种将不同层级的特征图进行融合以及联合预测目标的技术。但是这种网络设计会加大模型的计算量与复杂程度,其次它需要大量的数据集来进行训练以达到最

优效果,对于小数据集来说会产生过拟合的风险^[16]。因此本文采用了解耦头来代替 YOLOv5s 中的耦合头。

解耦头是目标检测领域中一种头部网络设计,其设计思想即是将目标检测任务分为分类和回归两部分,这种设计思想可以提高目标检测任务的精度和效率。

耦合头与解耦头的结构对比如图 5 所示,耦合头只通过一个 1×1 卷积将输入的特征图的通道减小到 33 然后直接进行分类和回归,如此就会产生模型过拟合的风险,而解耦头则是先通过一个 1×1 卷积将通道减小到 128,之后再分为两支,分别通过两个 3×3 卷积进行分类和回归两个任务。相比之下,解耦头保留了更多的信息,提高了精确率。这种设计能够更有效地保留各个任务的特征信息,并减少计算量。解耦头的两个分支分别进行独立优化,提升了模型的检测精度,特别是在处理复杂的目标边界和细节信息时,表现更好。

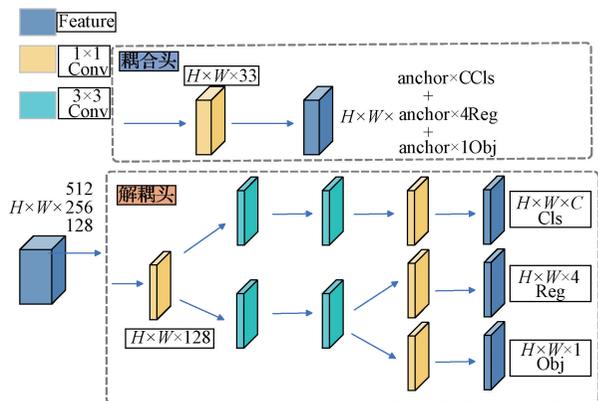


图 5 耦合头与解耦头的结构对比

Fig. 5 Structural comparison between coupling head and decoupling head

通过将分类和回归任务分离,解耦头避免了任务之间的互相影响,提高了模型的泛化能力和检测精度。在处理车辆起火中的火焰、烟雾等目标时,解耦头能够更准确地定位目标位置,同时保证分类结果的可靠性。

2.4 YOLOv5s-Fast 算法结构

本文针对充电站内车辆起火的检测算法 YOLOv5s-Fast 结构如图 6 所示。本文在 YOLOv5s 的基础上进行了 3 项关键改进。图 6 中红色模块即为改进的模块。Backbone 部分将 4 个 C3 模块更换为本文提出的与全局上下文注意力机制融合后的 C3GC 模块,其有效提升了深层次特征的提取能力,增强了模型在复杂背景下的识别精度。Neck 部分本文将上采样方式改为轻量级算子 CARAFE,解决了上采样过程中的信息丢失问题,显著提升了小目标检测的精度。Head 部分本文将原来的耦合头替换为解耦头 Decoupled Head,将分类任务和回归任务分离处理,减少了任务间的干扰,进一步提升了模型的检测精度和速度。

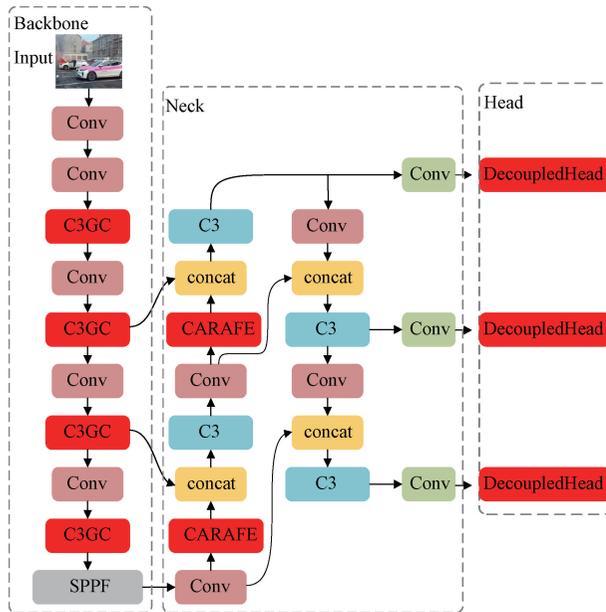


图6 YOLOv5s-Fast 算法结构

Fig. 6 YOLOv5s-Fast algorithm structure diagram

3 实验分析

3.1 数据集标记

本文使用的是公开的 Traffic-Net 数据集集中的车辆起火数据集,共 1 006 张车辆起火图像,如图 7 所示。



图7 车辆起火图像

Fig. 7 Vehicle fire image

使用 LabelImg 工具对数据集进行标记,标签采用 YOLO 格式,共划分 car、fire、smoke 3 种标签,其中 car 代表图像中的汽车、fire 代表起火点、smoke 代表烟雾、将标记好的数据集按 8 : 2 的比例划分训练集和测试集,训练集、测试集以及各种标签数量如表 1 所示。

3.2 实验配置及参数

本文所提出算法的实验环境是基于 Windows 10 操作系统下,使用 NVIDIA GeForce GTX 1650 作为硬件显卡, GPU 版本的 Pytorch 作为深度学习框架, Python 版本为 3.8.2, CUDA 计算库的版本为 12.1, 设置训练轮数 epoch 为 100。其中,动量为 0.937, 权值衰减为 0.000 5, 批量大小为 8, 学习率为 0.000 1, 输入图像尺寸为 640 × 640。

表 1 数据样本

Table 1 Data Sample

名称	数量
训练集	802
测试集	204
car	1 123
fire	1 058
smoke	673

精确率 (precision, P)、召回率 (recall, R) 和 mAP 是评估模型精度性能的 3 个关键指标。

$$P = \frac{T_p}{T_p + F_p} \quad (1)$$

$$R = \frac{T_p}{T_p + F_N} \quad (2)$$

$$L_{AP} = \int_0^1 P(R) dR \quad (3)$$

$$L_{mAP} = \frac{\sum_{i=0}^n L_{AP}}{n} \quad (4)$$

式中: P 表示真正例在预测样本中所占的比例; R 也称查全率, 表示样本中的正例占预测样本的比例; T_p 表示被正确预测为正样本的数量; F_p 表示为错误预测为正样本的数量; F_N 表示为模型错误预测为负样本的数量。 L_{AP} 表示平均精度 (average precision, AP), 是通过计算 P-R 曲线下面积得到的。 L_{mAP} 表示所有类别的 mAP, 用于衡量整体性能, 首先根据检测结果计算 P 和 R , 然后通过计算 P-R 曲线下面积, 得到每个类别的 AP, 最后将所有类别的 AP 值取平均, 即可得到 mAP。

此外, mAP@0.5 指将 IoU 设为 0.5 时计算每一个类别下所有图片的 mAP; 衡量模型的检测速度的指标为每秒传输帧数即每秒钟处理的图片数量, 帧率越高, 代表模型的检测速度越快。 衡量模型复杂度的指标为每秒浮点运算次数, 表示每秒执行的浮点运算次数, 常用来衡量模型的计算时间复杂度 (即计算量)。

3.3 实验结果分析

1) 消融实验对比

为了验证模型在加入 C3GC 模块、更换 CARAFE 上采样算子、更换检测头等改进内容的有效性, 本文进行了消融实验并对比结果。 实验数据如表 2 所示, 模型 0 是 YOLOv5s 算法; 模型 1 是 YOLOv5s + C3GC 模块; 模型 2 是 YOLOv5s + CARAFE 上采样算子; 模型 3 是 YOLOv5s + 解耦头; 模型 4 是融合上述 3 种改进后的最终改进型算法 YOLOv5s-Fast。 由表 2 可以看出, YOLOv5s 算法即模型 0 在对车辆进行起火检测时, 召回率明显偏低, 即证明未加改进的 YOLOv5s 算法存在许多漏检现象。 模型 1、2、3 相对于模型 0, 其 mAP@0.5 都有不同程度的提高, 尤其是召回率提升得尤其明显。

表 2 消融实验结果对比

Table 2 Comparison of ablation experiment results

模型	+C3GC	+CARAFE	+解耦头	$P/\%$	$R/\%$	mAP@0.5/ $\%$	检测速度/fps
0				72.3	54.3	61.0	46.225
1	✓			67.6	61.7	63.8	55.623
2		✓		66.9	62.2	61.1	49.289
3			✓	67.9	58.7	61.9	45.035
4	✓	✓	✓	68.1	62.1	65.9	59.462

模型 4 为融合 3 个改进点后的 YOLOv5s-Fast 算法, 比原 YOLOv5s 算法 mAP@0.5 高出了 4.9%, 帧率由 46.225 fps 提高到 59.462 fps, 并且精确率和召回率等指标均有不同程度的提升, 证明了 YOLOv5s-Fast 算法改进的有效性和实用性。

2) 检测结果对比

本文选择近期 4 张车辆起火图像来测试 YOLOv5s 算法和 YOLOv5s-Fast 的检测效果如图 8~9 所示。

图 8 是充电站车辆起火样本, 图 9 是 YOLOv5s 算法预测效果, 图 10 是 YOLOv5s-Fast 算法预测效果。图 9 和 10 在对部件定位的矩形框上显示标签类别以及置信度。由于本文研究目标是针对车辆在充电站内起火现象进行检测, 故将车辆周围烟雾与火苗都视为待检测目标, 这种检测机制确保了车辆周围无论是有烟雾或者是有火苗, 模型都能及时检测, 提高了车辆充电时的安全性。



图 8 充电站车辆起火样本

Fig. 8 Sample of charging station vehicle fire



图 9 YOLOv5s 预测效果

Fig. 9 Prediction performance of YOLOv5s



图 10 YOLOv5s-Fast 预测效果

Fig. 10 YOLOv5s-Fast prediction performance chart

图8中图像是从车辆起火视频中截取裁剪得到的,所以尺寸清晰度大不相同,且从未进行任何标记,从而使YOLOv5s算法在进行检测时效果不佳,出现了大量的漏检现象,而且其检测到的标签显示的置信度也偏低,不仅如此,YOLOv5s算法针对不同清晰度和尺寸的4张图像的检测效果也是有很大差异。

但是本文所提出的算法则很好地避免了这些问题。在识别精度方面:(1)得益于对于Backbone部分C3GC模块的应用,使得本文算法在提取上下文特征时更加全面;(2)得益于采用了轻量级上采样算子CARAFE,其是通过学习图像间的上下文关系进行自适应的上采样,而YOLOv5s的上采样中使用的邻近插值法则是通过相邻几个点的像素值来计算出待恢复的像素值,这种方法会使得YOLOv5s在上采样过程中出现大量的信息丢失,所以本文算法YOLOv5s-Fast在实际应用方面,尤其是在处理高像素高清晰度的图片时,效果明显优于YOLOv5s算法;(3)本文在Head网络部分更换为解耦头,它将分类和回归两个任务分开处理,相比于YOLOv5s中的耦合头,解耦头保留了更多的信息,提高了模型的精确率

在推理速度方面,YOLOv5s推理4张图像的平均用时为28ms,而本文所提算法YOLOv5s-Fast推理4张图像的平均用时仅为16ms。区别于YOLOv5s算法通过堆叠卷积层来传递提取信息,本文所提算法的推理速度的加快也是由于C3GC模块与轻量级上采样算子的使用,促进模型对上下文特征的充分提取,以及计算量的减少。

在模型复杂度方面,YOLOv5s的浮点数为16.1GFLOPs,而本文所提算法YOLOv5s-Fast的浮点数为16.2GFLOPs。浮点数是衡量模型复杂度与计算量的重要指标,由此可知,两者在模型复杂度上只有极小差别。

综上所述,证明本文所提算法在实用性与泛化性方面优于YOLOv5s算法,在处理图像时精度与推理速度都优于YOLOv5s算法,证明了本文算法改进的有效性。

3.4 实验对比

为了验证本文YOLOv5s-Fast模型的优越性,针对本文的车辆起火数据集,将其与多种主流检测模型进行了比较,如表3所示。首先Faster R-CNN算法的mAP@0.5最高,但是检测速度最小,因为其是双阶段目标检测算法,所以检测速度偏慢;其次YOLOv7、YOLOv8、YOLOv9与YOLOv5s算法都是单阶段算法,检测速度快,并且4种YOLO算法的mAP@0.5与检测速度都相差不大,但是YOLOv5s的模型大小小于上述3种YOLO算法,即YOLOv5s在实际部署时,只需要占用更少的计算资源。所以综合比较YOLOv5s算法更适合应用于工业实际领域,所以本文选择在YOLOv5s算法的基础上进行改进。通过实验数据证明,本文所提算法YOLOv5s-Fast相比于YOLOv5s在模型复杂度相差不大的前提下,具有更高的检测速度与精度,能够很好地满足在充电站内对车辆起火

检测的要求。

表3 模型性能对比

Table 3 Comparison of model performance

模型	mAP@0.5/%	检测速度/fps
Faster R-CNN	64.2	19.834
YOLOv7	58.9	42.563
YOLOv8	62.3	47.812
YOLOv9	51.7	35.450
YOLOv5s	61.0	46.225
YOLOv5s-Fast	65.9	59.462

4 结论

在充电站这种复杂环境中,起火和烟雾目标往往较小,容易与背景混淆,如何在提升检测精度的同时保持模型的实时性是本文拟解决的技术难点,为此本文提出了YOLOv5s-Fast算法。YOLOv5s-Fast算法的核心思路在于通过YOLOv5s算法的结构改进,在不显著增加计算复杂度的前提下提升检测精度和实时性,从而满足实际场景的要求,即在YOLOv5s基础上引入全局上下文注意力机制与原有C3模块融合,该机制通过捕捉全局特征增强模型的上下文特征提取能力,对车辆起火和烟雾检测的准确性有显著提升;并且引入轻量级上采样算子CARAFE和解耦头,减少了信息丢失与任务间的相互干扰,提升了小目标和复杂背景的检测效果。实验结果表明,YOLOv5s-Fast相较于YOLOv5s算法,在保持模型复杂度几乎相同的同时,平均精度提升了4.9%,检测帧率由原先的46fps提高到59fps,显著提高了模型的速度与精度。未来研究工作可以从如下3方面进行改进:1)扩展数据集的规模,提高模型的泛化性能;2)对模型的实时性以及资源消耗等进行更详细的评估,提高其在实际应用的可行性;3)针对漏检情况,对模型进行进一步改进,提高其检测性能。

参考文献

- [1] 黎子进. 新能源汽车起火原因分析及消防安全管理对策[J]. 今日消防, 2023, 8(11): 94-96.
LI Z J. New energy vehicle fires causes analysis and fire safety management countermeasures [J]. Fire Protection Today, 2023, 8(11): 94-96.
- [2] 吴志强, 廖承林, 李勇. 新能源电动汽车消防安全现状与思考[J]. 消防科学与技术, 2019, 38(1): 148-150.
WU ZH Q, LIAO CH L, LI Y. Current situation and consideration on fire safety of new energy electric vehicles [J]. Fire Science and Technology, 2019, 38(1): 148-150.
- [3] 徐玉珍, 邹中华, 刘宇龙, 等. 基于多尺度卷积神经网络和双注意力机制的V2G充电桩开关管开路故障信息融合诊断[J/OL]. 中国电机工程学报, 1-12 [2024-

- 07-10].
- XU Y ZH, ZHOU ZH H, LIU Y L, et al. Information fusion diagnosis of switching tube open-circuit fault in V2G charging piles based on multi-scale convolutional neural network and dual-attention mechanism[J/OL]. Proceedings of the CSEE, 1-12[2024-07-10].
- [4] 范云生, 张凯, 牛龙辉, 等. 海上无人机对运动船舶的长期检测跟踪算法[J]. 仪器仪表学报, 2024, 45(3): 326-335.
- FAN Y SH, ZHANG K, NIU L H, et al. Long term detection and tracking algorithm for moving vessels by maritime UAVs[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 326-335.
- [5] 钱承山, 沈有为, 孙宁, 等. 基于 Transformer 改进 YOLOv5 的山火检测方法研究[J]. 电子测量技术, 2023, 46(16): 46-56.
- QIAN CH SH, SHEN Y W, SUN N, et al. Research improved YOLOv5 forest fire detection method base-d on Transformer[J]. Electronic Measurement Technology, 2023, 46(16): 46-56.
- [6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779-788.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [8] 王雷, 赵清华, 张芯睿. 面向火灾的多尺度目标检测算法[J]. 计算机仿真, 2024, 41(1): 271-276, 310.
- WANG L, ZHAO Q H, ZHANG X R. A multi-scale object detection algorithm for fires [J]. Computer Simulation, 2024, 41(1): 271-276, 310.
- [9] 谢康康, 朱文忠, 谢林森, 等. 基于改进 YOLOv7 的火焰烟雾检测算法[J]. 国外电子测量技术, 2023, 42(7): 41-49.
- XIE K K, ZHU W ZH, XIE L S, et al. Improved YOLOv7-based flame smoke detection algorithm[J]. Foreign Electronic Measurement Technology, 2023, 42(7): 41-49.
- [10] 王召龙, 张洁. 基于改进的 YOLOv8 轻量级火灾检测算法研究[J]. 计算机技术与发展, 2024, 34(10): 61-68.
- WANG ZH L, ZHANG J. Research on lightweight fire detection algorithm based on improved YOLOv8 [J]. Computer Technology and Development, 2024, 34(10): 61-68.
- [11] 常丽, 张雪, 蒋辉, 等. 融合 YOLOv5s 与 SRGAN 的实时隧道火灾检测[J]. 电子测量与仪器学报, 2022, 36(8): 223-230.
- CHANG L, ZHANG X, JIANG H, et al. Real-time tunnel fire detection by fusion of YOLOv5s and SRGAN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 223-230.
- [12] HUANG J, HE Z, GUAN Y. Real-time forest fire detection by ensemble light weight YOLOX-L and defogging method[J]. Sensors, 2023, 23: 1894.
- [13] CAO Y, XU J, LIN S, et al. GCNet: Non-local networks meet squeeze-excitation networks and beyond[C]. CoRR, 2019, abs/1904.11492.
- [14] WANG J Q, CHEN K, XU R, et al. Carafe: Content-aware reassembly of features[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3007-3016.
- [15] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. ArXiv preprint arXiv: 2107.08430, 2021.

作者简介

阿斯卡·艾山, 副高级工程师, 主要研究方向为电网运行及智能电网建设。

E-mail: aishan@163.com

刘凯波(通信作者), 硕士研究生, 主要研究方向为目标检测。

E-mail: waitroad@sina.com

杨春萍, 副教授, 主要研究方向为人工智能。

E-mail: ychp@ncepu.edu.cn