

基于轻量化的神经网络火焰检测算法研究

陈义鑫¹, 王婷^{1*}, 杨万扣²

(1. 南京林业大学 信息科学技术学院, 江苏 南京 210037;

2. 东南大学 自动化学院, 江苏 南京 211189)

摘要:为了改善复杂背景情况下火焰检测算法检测效果较差、对小目标不敏感和计算量过大等缺陷,该文设计出一种轻量化的目标检测算法——GS-YOLOv5s。研究将鬼影混洗卷积瓶颈模块(GS bottleneck)应用于特征提取网络,提出跨阶段特征提取网络——GS-C2,通过对局部区域进行特征分流,使模型能够更专注地学习目标周围的局部特征,从而提高复杂背景下的目标检测精度;然后在模型的颈部网络中使用轻量化卷积GSConv,在实现模型轻量化的同时提高检测精度;最后通过融入选择性注意力LSK模块扩大感受野,更好地捕捉到全局上下文信息,提供更全面的场景理解,使网络更好地理解和响应小目标。数据集测试结果表明,与YOLOv5s基准模型相比,该算法结构整体参数数量和浮点运算量分别减少了约20%和21%,同时 $mAP_{0.5}$ 相较于YOLOv5s提高了4.6个百分点。实验结果表明,GS-YOLOv5s既提高了检测精度,又满足了轻量化以及实时检测的需求,极大提高了火焰检测算法的实用性。

关键词:目标检测;GSConv;跨阶段局部网络;注意力机制;SK模块

中图分类号:TP249

文献标识码:A

文章编号:1673-629X(2024)11-0200-07

doi:10.20165/j.cnki.ISSN1673-629X.2024.0256

Research on Flame Detection Algorithm Based on Lightweight Neural Network

CHEN Yi-xin¹, WANG Ting^{1*}, YANG Wan-kou²

(1. School of Information Science and Technology, Nanjing Forestry University, Nanjing 210037, China;

2. School of Automation, Southeast University, Nanjing 211189, China)

Abstract: In order to improve the defects of flame detection algorithms in complex background, such as poor detection effect, insensitivity to small targets and excessive computation, a lightweight object detection algorithm, GS-YOLOv5s, is designed. GS-C2, a bottleneck module, is applied to a feature extraction network, and a cross-stage feature extraction network is proposed. GS-C2 makes the model more focused on learning local features around targets, thus improving the accuracy of target detection in complex backgrounds. Then, the lightweight convolutional GSConv is used in the neck network of the model to improve the detection accuracy while realizing the lightweight model. Finally, by integrating selective attention LSK module to expand the receptive field, better capture the global context information, provide a more comprehensive understanding of the scene, so that the network can better understand and respond to small targets. Data set test results show that compared with the YOLOv5s benchmark model, the overall structure parameter number and floating point computation amount of the proposed algorithm are reduced by about 20% and 21% respectively, while $mAP_{0.5}$ is increased by 4.6 percentage points compared with YOLOv5s. The experimental results show that GS-YOLOv5s not only improves the detection accuracy, but also meets the requirements of lightweight and real-time detection, which greatly improves the practicability of flame detection algorithm.

Key words: object detection; GSConv; interphase local network; attention mechanism; SK module

0 引言

火灾是当今人类面临的主要灾害之一。如果在其

早期不能及时检测并进行抑制,就可能导致大规模安全事故,从而造成严重的财产损失和人员伤亡。目前

收稿日期:2023-11-16

修回日期:2024-03-19

基金项目:国家自然科学基金(62276061,62006041);江苏省研究生科研与实践创新计划项目(SJCX21_0338)

作者简介:陈义鑫(1998-),女,硕士研究生,研究方向为图像处理;通信作者:王婷(1980-),女,博士,副教授,研究方向为图像处理、时滞动态系统的稳定性研究;杨万扣(1979-),男,博士,教授,CFP会员(65560M),研究方向为模式识别与计算机视觉、自主智能无人系统。

的火灾检测系统大多是基于热成像和光学探测技术,然而,以这种方式获取的数据往往是冗余和模糊的,利用这些数据进行检测的结果通常不够准确,因此有必要研究更加高精度的火灾检测技术。同时为了将算法部署到嵌入式设备上,更加及时地检测到火灾,轻量化火灾检测技术应运而生。

目标检测是计算机视觉图像分析处理的基本任务之一,可以分为传统的目标检测方法和基于深度学习的目标检测方法。传统的目标检测方法大多基于人工预设参数阈值,泛化性能较差。基于卷积神经网络的目标检测方法作为深度学习目标检测的方法,可分为两阶段目标检测方法和单阶段目标检测方法。两阶段目标检测方法检测结果比较准确,但在实际应用中无法满足实时性要求。单阶段目标检测方法不需要单独提取候选区域,而是直接由输入图像得到目标类别概率和位置坐标,经过一个阶段即可直接得到最终的检测结果,因此具有更快的检测速度。

鲍文震等^[1]设计了一种结合感受野模块与并联区域建议网络的卷积神经网络 R-PRPNet 用于火焰检测。韩磊等^[2]提出了一种使用 BSO-ELM(天牛群算法-优化极限学习机)的新型火灾检测算法,优化了极限学习机寻找最优权值和阈值的能力。张大胜等^[3]结合火焰静态特征和动态特征,设计了多特征融合方法。陈露萌等^[4]在特征提取部分嵌入协同注意力机制模块,在不损失特征信息的情况下减少特征冗余,以帮助模型更精确地定位火焰特征。陈浩霖等^[5]提出一种由多卷积组合结构构建的主干网络——FIRE-Net,能够高效地从多个尺度上提取丰富的火焰特征。

然而以上深度学习算法结构复杂,其中密集的层数、高额的参数量以及浮点运算量等依然是亟待解决的问题,难以满足实时性要求。模型轻量化通过各种技术手段减小机器学习模型的体积和计算复杂度,以便在资源受限的环境中更高效地部署和运行模型。为了达到网络轻量化的目的,马成建等^[6]基于类 U-net 的编码器-解码器的架构提出一种轻量化火焰图像分割方法。李欣健等^[7]使用深度可分离卷积改进火焰检测模型的网络结构,实现在嵌入式移动系统上的实时火灾探测。周兴华等^[8]基于动态卷积思想,对 YOLOv5 颈部和头部进行剪枝,减少了模型参数,实现了视频火灾的动态实时准确检测。张融等^[9]以目标检测网络 FCOS 为基础,降低通道维数并选用 GhostNet 作为特征提取网络,实现了火灾的轻量化检测。赵英等^[10]采用改进的 ShuffleNetv2 网络单元组合重构 YOLOv5s 主干网络,提高了特征提取速度。赵伯亭等^[11]通过重参数化大内核卷积增强主干网络对目标特征的提取能力,有效降低了模型参数量。

为了实现在背景复杂和目标较小的情况下能及时检测到火焰的目的,该文设计了基于轻量化的目标检测算法—GS-YOLOv5s。首先通过重新设计跨阶段特征提取模块 GS-C2 实现在轻量化的同时获得更丰富的梯度信息,然后在颈部将传统卷积换为鬼影混洗卷积^[12]—GSConv,最后通过添加选择性注意力 LSK 模块扩大感受野,在实现轻量化的同时提高了模型检测精度。

1 火焰检测算法

1.1 整体架构

该文以提高检测模型的准确性和效率,同时减小规模等为出发点,选择 YOLOv5s 作为基准研究模型,融合新型 GSConv 技术,因此将模型命名为 GS-YOLOv5s。

模型整体架构如图 1 所示。

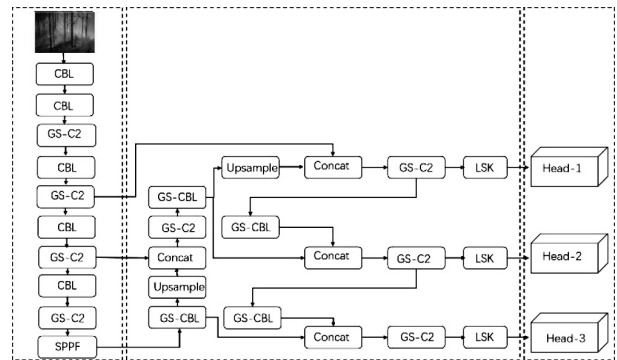


图 1 GS-YOLOv5s 模型整体架构

主干网络由 CBL、GS-C2 模块和空间金字塔池化模块(SPPF)组成。模型结构中“CBL”融合了卷积、归一化和激活等操作,“GS-CBL”则由 GSConv、归一化和激活函数构成。

1.2 轻量化跨阶段特征提取模块

CNNs 在各种计算机视觉任务中表现出优异的性能,然而传统的 CNNs 通常需要大量的参数和计算量才能达到令人满意的精度,同时卷积神经网络在对图像进行特征提取的过程中池化或者常规卷积等这些下采样操作往往会降低空间分辨率从而丢失信息。密集卷积计算最大限度地保留了每个通道之间的隐藏连接,现有的主流轻量级卷积网络架构中使用的稀疏卷积却完全切断了这些连接,使得模型的轻量化和高精度不可兼得,而图 2 中的 GSConv 以较低的时间复杂度尽可能地保留这些连接。数据重组是一种均匀混合策略,它允许来自密集卷积的信息完全混合到稀疏卷积的输出中,在不同的通道上均匀地交换本地特征信息,而不需要花哨的操作。对于轻量级检测器来说,GSConv 的优势更加明显,它得益于通过添加通道稀疏卷积核和数据重组增强非线性表达能力:首先使用

大量的 1×1 密集卷积来融合独立计算的通道信息,其次使用“通道混洗”来实现通道信息的交互,通过“减半”传统密集操作来保留通道之间的交互信息,最后使用数据重组将通道密集卷积运算生成的信息渗透到稀疏卷积生成的每一部分信息中。




图 2 GSConv 模块

如果在模型的所有阶段都使用 GSConv 则会加深模型的网络层数,从而加剧对数据流的阻力并显著增加推理时间。考虑到模型在颈部网络提取到的特征通道维度达到最大,宽度达到最小,故在此处使用 GSConv 对特征图进行拼接可最大程度减小信息冗余。将两个 GSConv 串联之后再和标准卷积进行并联的结构简称为 GS bottleneck,如图 3 所示。




图 3 GS bottleneck 模块

YOLOv5s 中的 C3 模块主要是对残差特征进行学习,它包含了 3 个标准卷积层以及多个 bottleneck 模块,然而 C3 模块在训练过程中参数量较大,检测速度较慢,导致其应用受限。因此,该文参照 ELAN 的特征分流融合的思想,将 GS bottleneck 通过分流的形式应用于跨阶段局部网络模块,得到如图 4 的模块结构。和 YOLOv5s 原本的含有三个卷积的 C3 模块相比它减少了一个卷积,故简称为 GS-C2,它在保证轻量化的同时能够获得更加丰富的梯度信息。




图 4 鬼影混洗卷积跨阶段局部网络模块(GS-C2)

1.3 选择性注意力模块—LSK 模块

在标准的卷积神经网络中,每层神经元的感受野被设计为相同大小。实际应用中的火灾检测有时由遥感拍摄,遥感图像中的物体尤其是小目标的精确检测通常需要参考更宽阔的测距环境即广泛的上下文信息,有限的上下文会导致误检或漏检,而且不同对象类

型所需的测距范围也不同,尤其是检测环境较为复杂,如存在大量负样本或者周围环境存在遮挡物等的情况下仅仅依靠目标本身的外观很难准确检测^[13]。考虑到遥感场景中特有的先验知识,该文引入拥有大型选择型内核的 LSK 模块^[14],能够动态地调整空间感受野,以便更好地模拟遥感场景中各种物体的上下文。

LSKNet 首次将大的核卷积应用于遥感任务,它提出的空间选择机制对由一系列大的深度卷积核提取出的特征进行加权,然后在空间上合并。该方法在空间维度上自适应地聚合跨大内核的信息,之所以在通道维度上没有对信息进行聚合是因为按通道选择无法对图像空间中不同目标的空间方差进行建模。图 5 是其详细的结构,直观地显示了大的选择性核是如何通过自适应地根据不同大小的对象来选择对应的感受野。




图 5 LSK 模块结构

图 5 为了从输入 X 的不同范围获得具有丰富上下文信息的特征,应用了一系列具有不同感受野的分解的深度卷积:

$$U_0 = X \quad (1)$$

$$U_{(i+1)} = F_i^{d_i}(U_i) \quad (2)$$

其中, $F_i^{d_i}(\cdot)$ 是具有核 k_i 和膨胀率 d_i 的深度卷积。假设分解出 N 个核,每个核都由 1×1 卷积层 $F^{1 \times 1}(\cdot)$ 进一步处理:

$$U_i = F_i^{1 \times 1}(U_i), \text{ for } i \text{ in } [1, N] \quad (3)$$

LSK 模块使用空间选择机制从不同尺度的大卷积核中空间选择特征图。将从具有不同感受野的不同核获得的特征连接起来:

$$\tilde{U} = [\tilde{U}_1, \tilde{U}_2, \dots, \tilde{U}_i] \quad (4)$$

之后通过相应通道的平均和最大池化来有效地提取空间关系,分别表示为 $P_{\text{avg}}(\cdot)$ 和 $P_{\text{max}}(\cdot)$ 。

$$SA_{\text{avg}} = P_{\text{avg}}(\tilde{U}) \quad (5)$$

$$SA_{\text{max}} = P_{\text{max}}(\tilde{U}) \quad (6)$$

其中, SA_{avg} 和 SA_{max} 分别为平均和最大池化的空间特征描述子。为允许不同的空间描述子之间的信息交互,LSK 模块将上一步得到的特征拼接起来并使用卷积 $F^{2 \rightarrow N}(\cdot)$ 将汇集的特征(具有 2 个通道)转换为 N 个空间注意力图。

$$\widehat{SA} = F^{2 \rightarrow N}([SA_{\text{avg}}; SA_{\text{max}}]) \quad (7)$$

对于每个空间注意力图 \widehat{SA} , 应用 sigmoid 激活函数获得每个分解的大核的单独空间选择掩码。

$$\widetilde{SA}_i = \sigma(\widehat{SA}_i) \quad (8)$$

其中, $\sigma(\cdot)$ 表示 sigmoid 函数。

由分解后的大核的一系列特征通过其相应的空间选择掩码进行加权, 并通过卷积层 $F(\cdot)$ 进行融合, 以获得注意力特征 S 。

$$S = F\left(\sum_{i=1}^N (\widetilde{SA}_i \cdot \widetilde{U}_i)\right) \quad (9)$$

LSK 最终输出是输入特征 X 和 S 之间的逐元素乘积, 即:

$$Y = X \cdot S \quad (10)$$

LSK 模块通过空间选择机制根据获得的多尺度特征动态选择各种对象的核。为了扩大网络关注的空间上下文区域以提高检测能力, LSK 使用空间选择机制, 通过应用基于通道的平均和最大池化来有效地提取空间关系。

2 实验

2.1 数据集描述

该文收集了包含有 4 200 张高质量不同火灾场景图片的火焰检测数据集并进行了注释, 其中数据集中有 3 739 张图片用于训练, 461 张图片用于验证, 并且设定了一定比例的负样本, 例如车灯、路灯、太阳光和消防员服饰等, 这些对象总被误认为是火焰并错误地触发警报。同时数据集中包含大量火灾初始阶段的小目标火焰, 用于判断模型对于小目标的检测能力。

2.2 评估指标和实验设置

在该领域, 常见的精确度评估指标包括准确率、召回率和平均精度, 轻量化评估指标包括参数量和浮点运算量 (即模型复杂度 FLOPs, floating point operations) 等。准确率 P 是指正确检测到的阳性样本数量与检测到的总数之比。召回率 R 是正确检测到的阳性样本数量与阳性样本总数的比率。mAP (平均精度) 用于定量评估检测精确度, 是衡量网络模型训练

的精确度的基本参数, 即 PR 曲线下所围成图形的面积。

mAP 右下角的数字是正样本被检测到的时候 IOU 的阈值, 如 $mAP_{0.5}$ 表示检测概率大于 0.5 即被检测到。准确率、召回率和平均精度公式如下:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (13)$$

$$AP = \sum_{i=1}^{n-1} (R_{i+1} - R_i) p(R_{i+1}) \quad (14)$$

其中, TP、FP 和 TN 分别表示真阳性、假阳性和假阴性。FLOPs 是指浮点运算数, 用来衡量算法模型的复杂度。参数量是指模型训练过程中的参数总量。浮点运算量以及参数量分别如公式 15 以及公式 16 所示。


$$FLOPs = k \cdot (H - s + 1) \cdot (W - s + 1) \cdot c \cdot k^2 \quad (15)$$

$$parameters = (s \cdot s \cdot n + 1) \cdot c \quad (16)$$

其中, 输入特征图长宽分别为 H , W , 有 k 个尺寸为 s 的卷积核, c 为输出通道数量, n 为输入通道数量, 式中的 1 代表卷积层的偏置。实验所用的显卡为 NVIDIA RTX3080Ti, 显存为 12G, 基于 PyTorch 3.8。

2.3 结果分析

该文将提出的方法与主流的二阶段检测方法以及一阶段检测方法进行比较。从表 1 中可以看出, Faster R-CNN^[20] 检测器检测精度较高, 然而模型参数量大, 检测速度较低; 而以 YOLO 系列为代表的一阶段检测器检测精度可与二阶段检测器相媲美, 同时检测速度更快。这些结果表明, 将通用对象检测器应用于文中的数据集并不能获得显著的结果。GS-YOLOv5s 相比较通用的对象检测器在自制的数据集上更具有竞争力, 该方法准确率达到 87.7%, 召回率达到 83.2%, 参数量和浮点运算量分别减少了 20% 和 21%, $mAP_{0.5}$ 相对于基准模型提高了 4.6 百分点, 显然该方法实现了精度和速度之间的平衡。图 6 分别绘制了以参数量和浮点运算量为横轴, 以 $mAP_{0.5}$ 为纵轴的散点图, 从中可以直观地看到 GS-YOLOv5s 获得了最好的结果。



(a) 主流一阶段检测器和二阶段检测器与 GS-YOLOv5s 的参数量和平均精度散点图; (b) 主流一阶段检测器和二阶段检测器与 GS-YOLOv5s 的浮点运算量和平均精度散点图

图 6 散点图

表1 不同方法在数据集上的检测结果

模型	准确率	召回率	mAP _{0.5}	FPS	参数量/M	浮点运算量/G
YOLOv5n ^[15]	0.813	0.712	0.823	132.4	1.8	4.2
YOLOv5s	0.875	0.762	0.838	136.1	7.0	15.9
YOLOv5m	0.833	0.803	0.853	140.5	20.9	48.2
YOLOv5l	0.864	0.788	0.856	143.7	46.1	108.2
YOLOv5x	0.874	0.782	0.864	149.4	86.2	204.6
YOLOv3 ^[16]	0.835	0.797	0.843	102.4	61.5	155.3
YOLOv4 ^[17]	0.567	0.884	0.781	73.4	64.4	60.4
YOLOv7	0.773	0.876	0.869	115.4	37.6	106.5
YOLOv8n	0.853	0.759	0.834	135.6	3.2	8.7
YOLOv8s	0.864	0.793	0.845	138.8	11.2	28.4
YOLOv8m	0.842	0.804	0.851	143.6	25.9	78.9
YOLOv8l	0.861	0.795	0.856	143.7	43.7	165.2
YOLOv8x	0.875	0.825	0.868	150.8	68.2	257.8
SSD ^[18]	0.63	0.883	0.782	168.9	26.3	62.7
Efficientdet ^[19]	0.837	0.738	0.798	54.6	3.9	5.2
Faster R-CNN ^[20]	0.802	0.613	0.753	29.0	137.1	370.2
R-PRNet ^[1]	0.854	0.783	0.828	137.4	34.6	40.5
FIRE-DET ^[5]	0.842	0.804	0.834	127.6	48.5	61.2
GS-YOLOv5s	0.877	0.832	0.884	150.1	5.6	12.6

图7将GS-YOLOv5s与基准模型YOLOv5s在平均精度、准确率、召回率和回归损失函数上进行了比较。当训练周期达到100时,精确率、召回率和平均精度mAP_{0.5}趋于稳定,同时GS-YOLOv5s的回归损失明

显低于YOLOv5s,之后的波动都在可接受范围之内。依据图7中的对比可得出,该文改进的方法在各项指标上都得到了一定范围的提升。

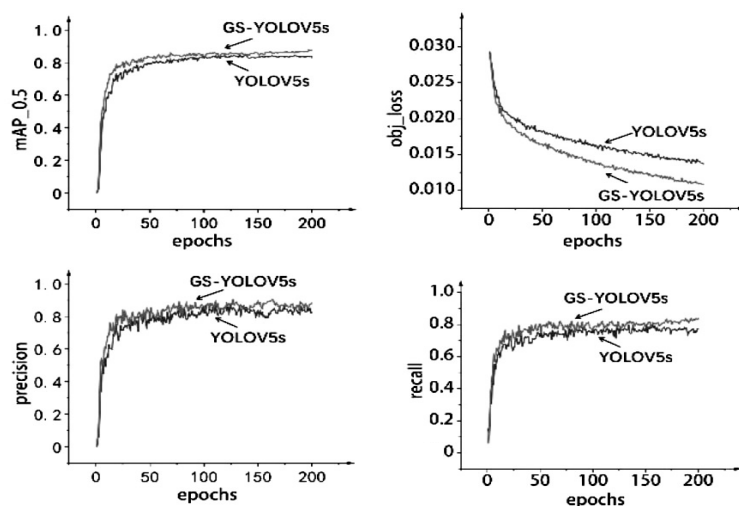


图7 GS-YOLOv5s和YOLOv5s的平均精度、准确率、召回率和回归损失函数比较

2.4 消融实验

本节验证了GS-YOLOv5s的有效性以及其中每个组件对最终性能的影响,在自制的数据集上进行了消融实验。以YOLOv5s为基准模型,依次添加GS-C2模块、GSConv以及LSK模块,所获得的消融实验结果如表2所示。添加了GS-C2模块的模型参数量

和浮点运算量与基准模型相比分别减少了20%和23.9%,mAP_{0.5}则提高了0.8个百分点,说明GS-C2模块在保证精度的同时能够减少模型参数量并降低模型复杂度。添加了GSConv的网络参数量和浮点运算量相较于基准模型分别减少了25.7%和25.1%,mAP_{0.5}提高了1.8个百分点,验证了加入GSConv后的模型能

表 2 对改进的模块进行消融实验

GS-C2	GSConv	LSK 模块	mAP _{0.5}	mAP _{0.5,0.95}	参数量/M	浮点运算量 /G
√			0.846	0.496	5.6	12.1
	√		0.856	0.513	6.6	15.4
		√	0.863	0.524	7.6	17.1
√	√		0.859	0.516	5.2	11.9
	√	√	0.872	0.525	7.1	16.0
√	√	√	0.884	0.532	5.6	12.6

够以较低的时间复杂度尽可能地保留通道之间的密集连接,从而提高检测精度。最后添加 LSK 模块,参数量和浮点运算量整体分别降低了 20% 和 21%,同时 mAP_{0.5} 提高了 2.5 个百分点。在整个过程中,其他条件相同。通过对单个模块的实验研究,验证了单个模块对最终模型性能的性能优化效果,最终证实了该文设计以及引用的模块在实现轻量化的同时提高模型整体精度。

2.5 算法对比可视化结果

将文中模型与之前的检测方法的检测结果进行可视化的比较。包括在计算机视觉领域广泛使用和改进的 Faster R-CNN、SSD、YOLO 系列等方法,对照组包括一阶段方法和两阶段方法。




图 8 复杂背景情况下的各种方法检测结果可视化

在实验数据集上,GS-YOLOv5s 的精确度很高,与其他现有的检测器相比,GS-YOLOv5s 具有更先进的性能。为了更加直观地说明检测性能,图 8 展示了在背景复杂的情况下使用基准模型 YOLOv5s、二阶段检测器 Faster R-CNN 以及 GS-YOLOv5s 的检测结果,并对结果进行了可视化。在图片中存在消防员服饰等负样本时,YOLOv5s 以及 Faster R-CNN 均存在误检漏检现象,检测结果较为不理想,而图 8(c)中 GS-YOLOv5s 的检测结果较好,对于具有迷惑性的负样本也能够较好地避开。图 9 分别展示了 YOLOv5s、Faster R-CNN 以及 GS-YOLOv5s 对于小目标的检测效果,在检测任务中小目标更容易漏检。YOLOv5s 以

及 Faster R-CNN 的检测结果中,一部分小目标以及被遮挡的目标容易被漏检,而图 9(c)中 GS-YOLOv5s 的检测结果较好,满足了在火焰检测中小目标的检测要求,这证实了 GS-C2 模块以及 LSK 模块的有效性(图 8 的图片分别来自网易订阅、江西消防、界面视频,图 9 的图片来自 kaggle 中的森林火焰数据集)。

根据图 8 以及图 9 中的可视化结果可以看出,GS-YOLOv5s 模型可以有效解决在背景复杂或者检测目标较小的情况下基准模型火焰检测算法的检测效果较差的问题,对于负样本也能够有效避免误报。




图 9 目标较小情况下的各种方法检测结果可视化

3 结束语

在 YOLOv5s 框架的基础上,针对火焰检测的困难和原本 YOLOv5s 的不足,提出了轻量级网络 GS-YOLOv5s 用于更加精确的火焰识别与定位。设计了一个新的特征提取模块——GS-C2,优化跨阶段局部网络对残差特征进行提取与学习,通过更多的分支跨层连接增加特征信息,在减少参数量和浮点运算量的同时提高检测精度。同时空间选择性注意力模块——LSK 扩大感受野,使得检测通过遥感拍摄的小目标结果更加准确。

在数据集上,这项工作已经取得了很好的效果,但仍有改进的空间,之后将主要致力于改进算法中的金字塔池化结构,同时改进头部网络检测头,寻找更强大的多尺度特征,并为嵌入式设备设计更快、更轻的检

测器。

参考文献:

- [1] 鲍文霞,孙强,梁栋,等.结合感受野模块与并行 RPN 网络的火焰检测[J].中国图象图形学报,2023,28(2):418-429.
- [2] 韩磊,曲娜,隋宇凡,等.基于 BSO-ELM 算法的火灾检测研究[J].消防科学与技术,2023,42(1):103-106.
- [3] 张大胜,肖汉光,文杰,等.YOLOv5 上融合多特征的实时火焰检测方法[J].模式识别与人工智能,2022,35(6):548-561.
- [4] 陈露萌,曹彦彦,黄民,等.基于改进 YOLOv5 的火焰检测方法[J].计算机工程,2023,49(8):291-301.
- [5] 陈浩霖,高尚兵,相林,等.FIRE-DET:一种高效的火焰检测模型[J].南京信息工程大学学报:自然科学版,2023,15(1):76-84.
- [6] 马成建,王学辉,吕玉乾.基于轻量化神经网络的火焰识别方法研究[J].消防科学与技术,2023,42(3):314-318.
- [7] 李欣健,张大胜,孙利雷,等.复杂场景下基于 CNN 的轻量火焰检测方法[J].模式识别与人工智能,2021,34(5):415-422.
- [8] 周兴华,陈西江,羊海东,等.动态卷积 YOLOv5 的视频火焰检测算法[J].测绘科学,2023,48(4):106-118.
- [9] 张融,张为.基于改进 GhostNet-FCOS 的火灾检测算法[J].浙江大学学报:工学版,2022,56(10):1891-1899.
- [10] 赵英,王琦,沙捷,等.基于 YOLOv5s 的轻量化乒乓球目标检测算法[J].计算机应用,2023,43(S1):229-234.
- [11] 赵佰亭,吴俊东,贾晓芬.融合特征增强的轻量化罐道缺陷检测算法[J].电子测量与仪器学报,2023,37(6):159-168.
- [12] LI H, LI J, WEI H. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles [J]. arXiv:2206.02424, 2022.
- [13] LI X, WANG W, HU X, et al. Selective kernel networks [C]//Computer vision and pattern recognition. [s. l.]: IEEE, 2019.
- [14] LI Y, HOU Q, ZHENG Z. Large selective kernel network for remote sensing object detection [C]//Computer vision and pattern recognition. [s. l.]: IEEE, 2023.
- [15] YAR H, KHAN Z A, ULLAH F U M, et al. A modified YOLOv5 architecture for efficient fire detection in smart cities [J]. Expert Systems with Application, 2023(Nov.):231.
- [16] REDMON J, FARHADI A. YOLOv3: an incremental improvement [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. [s. l.]: IEEE, 2018:8342-8351.
- [17] BOCHKOVSKIY A, WANG C Y, LIAO H M. YOLOv4: optimal speed and accuracy of object detection [J]. arXiv: 2004.10934, 2020.
- [18] 汪宋,费树岷.SSD(Single Shot MultiBox Detector)目标检测算法的研究与改进[J].工业控制计算机,2019,32(4):103-105.
- [19] TAN M, PANG R, LE Q V. EfficientDet: scalable and efficient object detection [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. [s. l.]: IEEE, 2020:10781-10790.
- [20] REN S, HE K, ROSS G, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(6):1137-1149.