

基于 Fast-CAANet 的火焰检测方法

龚成张¹, 严云洋^{1,2}, 卞苏阳¹, 祝巧巧¹, 冷志超¹

(1. 淮阴工学院计算机与软件工程学院, 江苏 淮安 223003)

(2. 江苏海洋大学计算机工程学院, 江苏 连云港 222005)

[摘要] 高效率高速度的火焰检测方法对预防火灾、保护社会安全具有十分重要的作用。本文面向社会安全应用需求, 提出一种基于 Fast-CAANet 的火焰检测方法。先提出一种 CAA 模块, 加强卷积和注意力机制的有效融合; 然后构建 CAANet 网络的主干网络 (CAABlock), 更有效提取火焰的丰富特征; 再提出参数更小、准确度更高的 Fast-CAABlock 模块, 提出了加强火焰特征提取的方案。实验结果表明, Fast-CAANet 准确率达到 91.42%, 计算量 3.9 GMac 较小。所提火焰检测算法与其它算法相比, 性能更优, 效果更好。

[关键词] 深度学习, 特征提取, 注意力机制, 火焰检测

[中图分类号] TP391.44 **[文献标志码]** A **[文章编号]** 1001-4616(2024)02-0109-08

Flame Detection Based on Fast-CAANet

Gong Chengzhang¹, Yan Yunyang^{1,2}, Bian Suyang¹, Zhu Qiaoqiao¹, Leng Zhichao¹

(1. Faculty of Computer & Software Engineering, Huaiyin Institute of Technology, Huaian 223003, China)

(2. School of Computer Engineering, Jiangsu Ocean University, Lianyungang 222005, China)

Abstract: High efficiency and high speed flame detection plays an important role in preventing fire and protecting social security. In this paper, a flame detection method based on Fast-CAANet is proposed to meet the needs of social security applications. Firstly, a CAA module is proposed to strengthen the effective integration of convolution and attention mechanism. Then the main network of CAANet (CAABlock) is constructed to extract the rich characteristics of flame more effectively. The Fast-CAABlock module with smaller parameters and higher accuracy is proposed to enhance the flame feature extraction scheme. Experimental results show that the accuracy of Fast-CAANet is up to 91.42%, and the calculation amount is 3.9 GMac. Compared with other algorithms, the proposed flame detection algorithm has better performance and effect.

Key words: deep learning, feature extraction, attention mechanism, flame detection

对于不断城市化的社会来说, 火灾的发生率居高不下, 每年都会有多起火灾事故, 严重威胁社会的生命和财产安全。如: 2021 年 6 月 25 日, 河南省柘城县远襄镇北街村震兴武馆发生重大火灾事故, 造成 18 人死亡、11 人受伤^[1]; 2022 年 1 月 9 日, 美国纽约布朗克斯区一栋高层住宅楼发生火灾, 造成 19 死、63 伤^[2]。观其特点, 火灾事故具有起火种类多、伤害大、破坏力强、不可控性高等特点。成功的预防可以减少火灾的初起规模, 及时将火焰扑灭在萌芽中。同时也能降低燃烧产生的有害物质或爆炸造成的二次伤害, 减少社会的经济损失。

本文针对火灾检测任务, 对火灾成型进行思考, 归纳火灾检测的重点, 以时间为索引的形式对火灾检测方法进行概括, 并对目前基于深度学习的火焰检测方法进行改进。

1 相关工作

火焰是火灾的重要特点, 对火焰特征的有效提取是火焰检测的基本要求。目前火焰的识别方法主要

收稿日期: 2023-06-16.

基金项目: 国家自然科学基金项目 (61402192)、江苏省“六大人才高峰”项目 (2013DZXX-023)、江苏省“青蓝工程”、淮安市“533 英才工程”项目。

通讯作者: 严云洋, 博士, 教授, 研究方向: 数字图像处理、模式识别。E-mail: yunyang@hyit.edu.cn

可以分为以下几个阶段:

(1) 依靠温度传感器、烟雾传感器去识别火焰,如陈亚光等^[3]提出利用烟雾浓度或温度超过限定后实现声光报警和电话报警;Kim 等^[4]使用新的视觉传感器用于火灾监控.但这些方法对传感器依赖度太高,往往存在距离近、范围小等缺点.

(2) 依靠传统学习方法^[5]提取火焰特征,如张慧珍等^[6]提出一种基于超像素分割并结合闪频特征进行判断识别的方法;Gong 等^[7]计算每帧质心来解决火焰的不规则性,利用火焰动态特征以及颜色空间检测火焰,但这些方法存在无固定参考点,泛化能力不足等缺点. Kim 等^[8]提出一种多输出编码器-解码器的可靠火灾检测框架,虽然这种方法比依靠手工提取的方法有众多进步,但是依然未能避免人工操作的缺点.

(3) 依靠深度学习的火焰识别方法. 深度学习在各个领域都有成效,如梁秦嘉等^[9]提出改进 YOLOv3 模型研究交通视频;石跃祥等^[10]提出协作卷积 Transformer 网络去识别骨架动作. 在火焰识别中,通过学习火焰的特征来检测火焰,不设置过多参数,学习的特征用来火焰分类,如严忱等^[11]提出一种融合多级特征的视频火焰检测方法;Hosseini 等^[12]提出一种高效卷积神经网络架构 UFS-Net 去检测视频帧中的火焰和烟雾.

依靠深度学习的火焰检测方法通过计算机提取火焰的特征,实现输入与输出的实时传输,极大的提高了火焰从产生到发现的速度,在保证速度的基础上,有很好的识别能力. 基于深度学习,本文提出一种基于 Fast-CAANet 的火焰检测方法:先提出一种 CAA 模块,该模块既有提取局部特征的卷积网络,又有增强全局感知能力的注意力机制;然后将 CAA 模块应用到 ConvNext 中,提出 CAABlock 模块,构建 CAANet 网络;再对 CAABlock 模块进行轻量化设计,构建 Fast-CAANet 模块,在减少计算量和参数的基础上,进一步提升预测的准确性.

2 Fast-CAANet 的火焰检测方法

2.1 Fast-CAANet 网络

Fast-CAANet 是端到端的深度学习检测网络,符合深度学习算法的结构. Fast-CAANet 检测器的整体架构遵循 ConvNext^[13]的结构. Fast-CAANet 创新结构主要为两步:第一步加入 CAA 模块构成 CAABlock 模块,可在结合卷积和注意力机制的优点上,获取火焰的阶段特征;第二步生成新的模块 Fast-CAABlock, Fast-CAABlock 对 CAABlock 进行参数简化,不仅提升了 Fast-CAANet 的准确性,而且减少了分类的计算量,在优化网络上发挥了重要作用. CAABlock 和 Fast-CAABlock 的提出,增强了火焰的特征全局感知,增加火焰特征在卷积过程中的关联性,提升检测器对火焰特征的敏感性.

为了使网络更加轻量,速度更快,在 Block 模块中使用深度可分离卷积,这使 CAANet 和 Fast-CAANet 有更好的速度与性能. 图 1 为 CAANet 和 Fast-CAANet 的网络结构,其中 LN 为归一化操作,DownSample 为下采样操作,GAP 为全局平均池化操作,head 识别火焰对象.

2.2 Fast-CAANet 模块

2.2.1 Block 模块

本文的 Block 模块,由深度可分离卷积模块、归一化、Conv 模块和激活函数组成,其模块可以表示为式(1):

$$g(x) = \text{Conv}^1 \otimes \text{gelu} \otimes \text{Conv}^2 \otimes \text{LN} \otimes S(x), \quad (1)$$

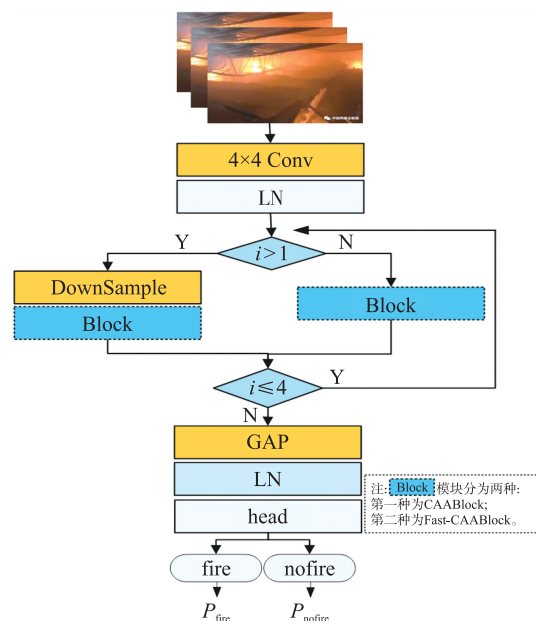


图 1 CAANet 和 Fast-CAANet 网络结构

Fig. 1 CAANet and Fast-CAANet network structures

式中, $CAABlock$ 中 $Conv^2$ 为 CAA 模块, $Fast-CAANet$ 中 $Conv^1$ 和 $Conv^2$ 为 CAA 模块, LN 为归一化操作, $gelu$ 为激活函数, S 为深度可分离卷积, g 为 $Block$ 模块的输出。

2.2.2 深度可分离卷积模块

一个可分离模块 i 可以用一个函数 $y_i = f_i(x_{(h,w,c)})$ 表示, 其中 y_i 代表运算 i 的输出张量, x 是输入张量, k 是 f 中卷积核大小, h 和 w 分别为输入张量的高和宽, c 是输入通道数。所以一个卷积模块可以分为多个模块 i , 即卷积模块的结构示意图可以表示为式(2):

$$S = y_n(\cdots(y_2(y_1))) = y_n \otimes \cdots \otimes y_2 \otimes y_1 = \bigotimes_{m=1 \cdots n} f_m(x_{(h,w,c)}). \quad (2)$$

在实验中,深度可分离卷积模块^[14]通常以逐通道卷积和逐点卷积展开。图2(a)逐通道卷积卷积核和通道一一对应,图2(b)逐点卷积在深度方向上加权组合。这样操作使得模型具有较小的参数量和计算量。图2为深度可分离卷积模块的两种表现形式。

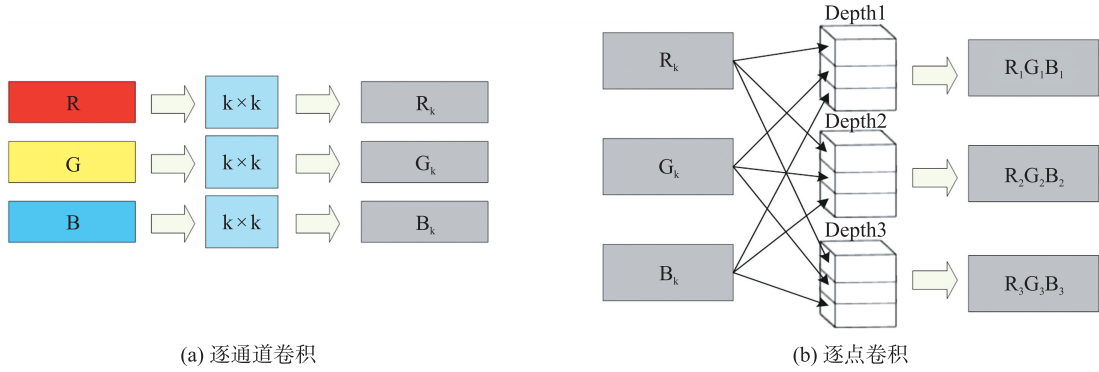


图2 深度可分离卷积模块

Fig. 2 Depth-separable convolution module

2.2.3 CAA 模块

传统的 $Block$ 模块仅使用卷积方法对火焰特征进行提取, 这样虽然能提取丰富的局域特征, 但是在全局感知上依然受限, 不能融合全局信息, 不适合火焰的特征提取。本文发现通过将传统的卷积模块变成卷积注意力结合模块(CAA)会获得更好的准确性, 该模块汲取注意力模块^[15]的优势, 也更好地融合卷积的深度提取特征。 CAA 模块如图3所示。

CAA 模块将输入的张量分别进行卷积和注意力机制操作, 图左部分为注意力模块, 其作用是对输入进来的张量进行 1×1 卷积, 得到 query、key 和 value 值, 右边部分是卷积操作, 其作用是进行 3×3 卷积得到对应的张量。设 $x_{in}^{c \times h \times w}$, $x_{out}^{c \times h \times w}$ 为输入与输出特征, W_q, W_k, W_v 分别为 query、key 和 value 的投影矩阵, $f_o \in x_{in}^{c \times h \times w}$, $f_p \in x_{out}^{c \times h \times w}$ 分别表示像素对应的张量, 则注意力模块可以表示为式(3):

$$H(x) = g(W_q f_o, W_k f_p) W_v f_p, \quad (3)$$

式中, $g(W_q f_o, W_k f_p)$ 表示 x 对应的权重; g 的表达公式可以表示为式(4):

$$g(W_q f_o, W_k f_p) = \text{softmax}\left(\frac{(W_q f_o)^T W_k f_p}{\sqrt{d}}\right). \quad (4)$$

对于右侧卷积操作, 对应的是一个 3×3 的卷积, 卷积的表达公式如式(5)所示。

$$I(x) = \text{Conv}(x^{(c,h,w)}). \quad (5)$$

因此, CAA 模块可以表示为式(6):

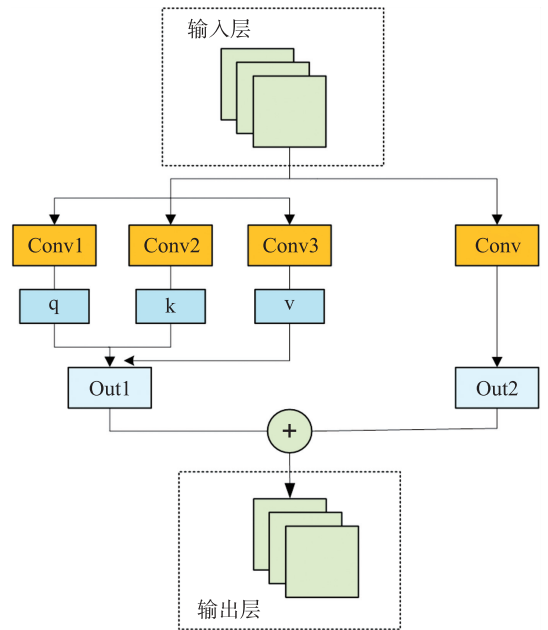


图3 CAA 模块

Fig. 3 CAA module

$$S(x)=\alpha H(x)+\beta I(x)=\alpha g(W_{qf_o},W_{kf_p})W_{wf_p}+\beta Conv(x^{(c,h,w)}),$$

(6)

式中, α,β 为卷积注意力模块的比例,通过模型自学习而来,且 $\alpha,\beta\in(0,1),\alpha+\beta=1$.

2.2.4 构建 CAANet 网络

为了实现更有效的火焰检测算法,将 CAA 模块加入到火焰特征提取的主干部分,并将其命名为 CAANet Block. 该结构通过卷积提取浅层火焰信息,通过卷积注意力结合提取深层火焰特征. 表中每一行代表一次操作,每层详细介绍了操作步骤 $f(x_i)$ 、分辨率 $h\times w$ 、输入通道 $c_{(in)}$ 和输出通道 $c_{(out)}$,表 1 以 $x^{(96,56,56)}$ 为例.

表 1 CAANet Block 网络结构
Table 1 CAANet Block network structure

Stage/ i	Operate/ $f(x_i)$	Resolutions/ $h\times w$	$C_{(in)}/c_{(in)}$	$C_{(out)}/c_{(out)}$
1	Save= x	56×56	96	96
2	7×7Conv, $P=3$	56×56	96	96
3	LN	56×56	96	96
4	1×1Conv, $c\times 4$	56×56	96	384
5	GELU	56×56	384	384
6	CAA, $c/4$	56×56	384	96
7	Concat,Save+ $f(x_6)$	56×56	96	96

虽然 CAA 的加入并没有改变模型的分辨率,但是它更好地利用了卷积和注意力的优势. 在一个 Block 模块里:

- 第 1 步:使用残差块 Save,将输入的张量 x 先保存;
- 第 2 步:使用一个 7×7 卷积,获得一个更大的感受野;
- 第 3 步:使用 LN 正态分布标准化,减少数据依赖和数据冗余;
- 第 4 步:使用一个 1×1 卷积增大输出通道数,达到使用更少参数数量目的;
- 第 5 步:使用 GELU,引入随机性,使得模块训练更加鲁棒;
- 第 6 步:使用 CAA 模块,在输出通道时变回起始通道数,方便进行残差块连接;
- 第 7 步:使用残差块连接,首先将第 6 步输出结果随机丢失,然后进行 concat 操作,这样可以获取更好的火焰特征.

2.3 构建 Fast-CAANet 网络

虽然 CAANet 在识别火焰上有进步,但是其参数和计算量都有较明显的提升,所以在 CAA 模块的基础上,进一步降低模型的参数量和计算量,提出了一种更好的网络结构 Fast-CAANet. Fast-CAANet 在不改变 CAABlock 模块步骤的基础上,对模型参数量进行降低,通过对 CAA 模块多次调用,将 1×1 卷积替换成 CAA 模块,取消其模型对通道的扩充,进一步减少模型的参数量. 实验结果发现,Fast-CAANet 无论在精度、模型计算量和参数上,性能都取得了很大的提高. 图 4 为改进的模块.

在 Fast-CAANet 网络中,会将网络通道数按照 96、192、384、768 维度进行,这样设计模型主要参考 ViT^[16] 的设置构思,能够很好地对火焰特征进行提取. 网络以 224×224 大小的 3 通道图像作为输入,通过 4×4 卷积,得到输出为 56×56 的 96 通道向量,进而通过下采样和 Block 模块,将向量依次按照 192、384、768 通道数进行

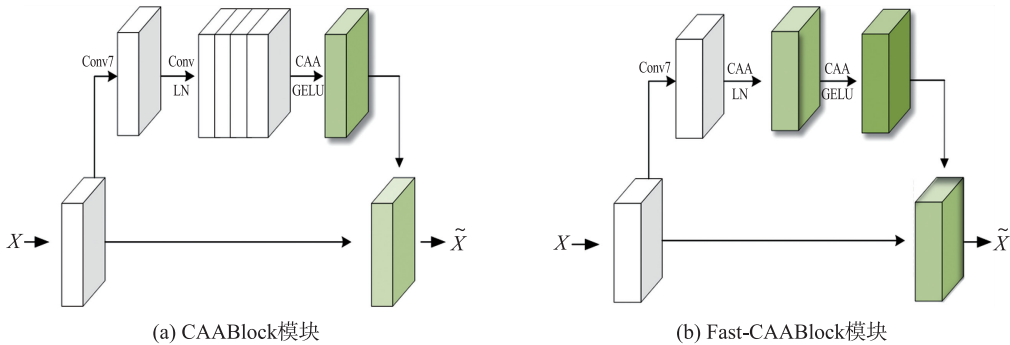


图 4 CAABlock 和 Fast-CAABlock 模块
Fig. 4 CAABlock and Fast-CAABlock module

输出,这样操作使得 CAA 模块得到更多次数的使用,能够更深地捕获火焰图像的局部结构,也能更好地学习每一张图片之间的全局相互作用. Fast-CAANet 与最先进的分类器相比,其准确率更高,参数更少,计算复杂度更低,表明网络结构能够更好地实现火焰的检测分类,使其更有效地获取火焰特征.

3 实验与分析

3.1 实验环境

本文实验所需环境如表 2 所示:

3.2 实验训练数据集

由于火灾研究缺乏公共数据集,本文收集互联网上不同场景下的火焰图片构成火焰训练集;使用 PASCAL VOC 数据集按照一定比例构建非火焰的训练集. 图 5 为实验所用的数据样图,其中 image1-image4 为火焰样图,火焰图包括小目标,多目标火焰数据;images5-images8 为非火焰样图,非火焰图包括各种场景和类似火焰数据.

表 2 实验环境

Table 2 Experimental environment

环境参数	
操作系统	Windows 10 专业版
CPU	i5-9500 CPU
GPU	GeForce GTX GTX1650
RAM	16 GB
ROM	固态 500 G
Python	Python3.8



图 5 数据样图

Fig. 5 Data sample diagram

3.3 实验过程

本实验采用 Pytorch 框架搭建深度学习模型,图层初始值设为 $1e-6$,输入尺寸统一设为 224×224 . 人工采集的火焰图片易受各种因素干扰,因此为了提高采集数据的训练效果,数据集采用平移、裁剪和增加噪声等方法进行数据增强.

在实验中,所有对比实验在相同环境、数据集上训练 100 个周期,验证 CAANet 和 Fast-CAANet 的有效性. 并进行了消融实验,确保本文提出的算法得到验证.

3.4 评价方式

3.4.1 混淆矩阵

由混淆矩阵衍生的准确率 (Acc)、精确率 (Pre)、召回率 (Rec) 是实验评价的重要指标. 表 3 为混淆矩阵.

其中 TP 为 True positive (真阳性), FP 为 False Positive (假阳性), FN 为 False Negative (假阴性), TN 为 True Negative (真阴性). 由于实验将数据集分为有火和无火两类,所以 TP、FP、FN 和 TN 四个参数都是必要的.

表 3 混淆矩阵

Table 3 The confusion matrix

火焰图	预测	
	正火	负火
正火	TP	FN
负火	FP	TN

准确率 (Acc) 是预测正火的样本数占正火焰图样本的比例,准确率越高代表网络模型分类越好,计算公式为式(7):

$$Acc = \frac{1}{n} \sum_{i=1}^n (S+1)_{if(f(x_i)=TP//TN)},$$

(7)

式中, S 初始值为 0, f 为预测步骤;

精确率 (Pre) 是预测正样本数占有所有预测正火比例,计算公式为式(8):

$$Pre = \frac{TP}{TP+FP}.$$

(8)

召回率 (Rec) 是所有预测正值中火焰正确预测占比,计算公式为式(9):

$$Rec = \frac{TP}{TP+FN}.$$

(9)

3.4.2 参数量和计算量

参数量 (Params) 和计算量 (Flops) 是评价一个网络的重要指标. 在检测精度较高的基础上,模型参数越小,对模型运算需要的设备要求也就越低;模型的计算量越少,对应着网络的复杂度也就越低. 但在实验中,因参数量和计算量计算代码不同,会导致结果有误差,所以在对比实验中参数量和计算量采用相同的计算代码结构计算.

3.5 实验结果

表 4 为实验用到的验证集来源. 由于在模型中使用了数据增强和卷积注意力结合机制,对于不同颜色不同大小的火焰特征都有较好的效果. 模型自身采用深度可分离卷积的方法,减少计算量,增加模型训练中特征提取;使用 Fast-CAABlock 结构构建 Fast-CAANet 网络,将模型参数量和计算量降低一半,提升识别器对火焰特征的提取速度;对于小目标火焰,CAA 模块有卷积和注意力的双重优势,能够更精准的定位火焰特征. 对于非火焰图像也不会产生过多的误检,CAA 模块中 Attention 结构的多次调用确保非火焰物体按照非火方式被检测出来.

本文将 CAANet、Fast-CAANet 与其它算法进行比较. 对比算法包括 DenseNet^[17]、ViT、Swin Transformer^[18-19] 和 ConvNext. 如表 5 所示,可以发现,CAANet 的性能普遍高于其它算法,虽然在精准率上比 Swin Transformer 低 1.71%,但是在召回率上高出 4.89%,这也表明,CAANet 在火焰识别中更具优势;基于 Fast-CAANet 模型的识别方法在准确率、精确率和召回率上均高于其它算法,获得较好的性能.

本文在比较模型准确率、精确率和召回率后,分析模型的参数量和计算量,进一步用实验解释 Fast-CAANet 的由来. 通过对比算法模型的大小和计算复杂度得到表 6,表中 CAANet 在模型参数和计算量上和其它算法相比存在较大的差距,仅低于 ViT,这使得本文将目光放在降参和降复杂度上. Fast-CAANet 在减少参数量后,其计算量逼近轻量型网络 DenseNet,虽在参数量上不及 DenseNet,但在准确率、精确率和召回率上远超 DenseNet,并且 Fast-CAANet 参数量和计算量优于 DenseNet 以外的所有算法,做到兼顾识别效果和性能两大特点.

表 5 实验效果对比

Table 5 Comparison of experimental effects

算法	Acc/%	Pre/%	Rec/%
DenseNet	78.99	64.77	85.53
ViT	79.44	65.35	85.81
Swin Transformer	87.00	78.42	85.90
ConvNext	85.80	75.00	88.16
CAANet	87.33	76.71	90.79
Fast-CAANet	91.42	85.03	91.14

表 6 模型参数量和计算量对比

Table 6 Comparison of the number of model parameters and calculation amount

算法	Params (M)	Flops (GMac)
DenseNet	6.96	3.88
ViT	85.8	16.85
Swin Transformer	27.52	4.35
ConvNext	27.82	4.47
CAANet	54.26	8.87
Fast-CAANet	22.45	3.9

另外,本文的消融对比实验对应表 5 与表 6,实验结果比较如表 7 所示. 实验将 ConvNext 设为对照组, O 表示 CAANet 网络,OT 组合表示 CAANet-min 网络,OTh 组合表示 Fast-CAANet 网络. 第 1 组实验将 CAA 模块加入实验中,在加入 CAA 模块后的模型比对照组模型的准确度高出 1.53 个百分点,精确度高出 1.71 个百分点,召回度同样也高出 2.63 个百分点,这主要是因为注意力机制增强了火焰特征的提取. 但是在加入 CAA 模块后,模型的数量和计算量都得到了较高的增加. 考虑到 CAA 模块拥有更多的注意力特征,所以对于 CAANet 中 1×1 卷积,不需要其升维,增加非线性能力;于是第 2 组实验的 1×1 卷积输入与输出通道数不变,进入 CAA 模块时,仅使用卷积和注意力方法对其进行火焰特征处理,忽略通道上的非线性变化,但实验结果中 Acc、Pre 和 Rec 都有明显的下降,随即意识到要在保证性能的基础上降参, 1×1 卷积也需要被替换掉,CAANet-min 仅验证了该方法可以成功降低参数量和计算量;第 3 组实验在 CAANet 基础上替换 1×1 卷积,并调小参数量,计算量仅有 3.9 GMac,所有评价标准都优于对照组,也同样优于 CAANet 网络. 实验结果表明,Fast-CAANet 网络与 CAANet 网络通过 CAA 模块的组合,可以增加火焰特征提取效果,进而提高火焰识别效率.

表 7 消融对比实验
Table 7 Comparative ablation experiments

Stage/i	O	T	Th	Acc/%	Pre/%	Rec/%	Params	Fps
1				85.80	75.00	88.16	27.82	4.47
2	✓			87.33	76.71	90.79	54.26	8.87
3	✓	✓		75.31	60.17	83.83	15.42	2.62
4	✓		✓	91.42	85.03	91.14	22.45	3.9

4 结论

本文针对火灾检测问题,提出一个新的火焰检测方法 Fast-CAANet,CAANet 从识别效率出发, Fast-CAANet 在结合效率的同时也兼顾模型复杂度. Fast-CAANet 在 CAANet 的基础上,不仅优化了模型参数,而且实现了更准确的效果. 在主干部分,多次利用卷积的局部提取能力和注意力的全局感知优势,利用卷积提升模型感受野,利用注意力机制提高模型的准确性. 在面对多火焰、小目标和复杂目标时,本文对比其它主流算法,都能达到性能更佳,模型参数更好的效果. Fast-CAANet 和 CAANet 在消融对比试验中,也体现 CAANet 的构建初衷,以及如何通过对比实验得到 Fast-CAANet. CAA 模块的组合使用,构建出一个精度较高,参数较低的高效 Fast-CAANet 网络. 然而本文的检测方法依然受限于数据集的选择,在以后的研究中会将小样本问题和更加正规的数据集带入模型中研究,进一步提高网络的准确性和识别效果.

[参考文献]

[1] 中国消防. 河南震兴武馆“6·25”火灾事故责任人被查处[J]. 中国消防,2022(1):42-43.
[2] 刘宇. 关于推进落实高层民用建筑消防安全主体责任的认识与思考[J]. 法制博览,2022(15):141-143.
[3] 陈亚光,陈云,侯建成,等. 基于单片机的烟雾报警器设计与实现[J]. 辽宁科技学院学报,2016,18(5):4-6.
[4] KIM H,PARK J. Fire flame detection based on color model and motion Estimation[C]//2016 IEEE International Conference on Consumer Electronics-Asia(ICCE-Asia). USA:IEEE,2016.
[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] 张慧珍,严云洋,刘以安,等. 基于超像素分割与闪频特征判别的视频火焰检测[J]. 数据采集与处理,2018,33(3):512-520.
[7] GONG F,LI C,GONG W,et al. A real-time fire detection method from video with multifeature fusion[J]. Computational intelligence and neuroscience,2019,2019(1):1939171.
[8] KIM Y J,KIM H,LEE S,et al. Trustworthy building fire detection framework with simulation-based learning[J]. IEEE access,2021,9:55777-55789.
[9] 梁秦嘉,刘怀,陆飞. 基于改进 YOLOv3 模型的交通视频目标检测算法研究[J]. 南京师范大学学报(工程技术版),2021,21(2):47-53.

- [10] 石跃祥,朱茂清. 基于骨架动作识别的协作卷积 Transformer 网络[J]. 电子与信息学报,2023,45(4):1485-1493.
- [11] 严忱,严云洋,高尚兵,等. 基于多级特征融合的视频火焰检测方法[J]. 南京师大学报(自然科学版),2021,44(3):131-136.
- [12] HOSSEINI A, HASHEMZADEH M, FARAJZADEH N. UFS-Net: a unified flame and smoke detection method for early detection of fire in video surveillance applications using CNNs[J]. Journal of computational science,2022,61:101638.
- [13] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. USA:IEEE,2022:11976-11986.
- [14] CHEN H Y, SU C Y. An enhanced hybrid MobileNet[C]//2018 9th International Conference on Awareness Science and Technology (iCAST). USA:IEEE,2018:308-312.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in neural information processing systems,2017,30.
- [16] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words:transformers for image recognition at scale[J/OL]. arXiv Preprint arXiv:2010. 11929,2020.
- [17] HUANG G, LIU Z, van der MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA:IEEE,2017:4700-4708.
- [18] LIU Z, LIN Y, CAO Y, et al. Swin transformer:hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. USA:IEEE,2021:10012-10022.
- [19] 林诗妍,刘宇翔,魏宏安. 基于边缘计算的鱼眼相机高空抛物检测系统[J]. 福建师范大学学报(自然科学版),2024,39(6):52-62.

[责任编辑:杜忆忱]