

# 基于 YOLOv3-tiny 的火焰目标检测算法

徐 岩,李永泉,郭晓燕,韩立苏,刘巧玲

(山东科技大学 电子信息工程学院,山东 青岛 266590)

**摘要:**基于 YOLOv3-tiny 网络提出一种满足实时性需求的火焰目标检测算法,解决现有一般算法在自制火焰数据集上检测效果不佳的问题。通过构建 CSP-MobileNetV2 结构并引入到骨干网络池化层替换原始卷积层,提升网络的特征提取能力;引入选核注意力网络(SKNet),使卷积核对不同尺寸的火焰目标实现自适应调整,增强了对火焰特征的提取能力;引入金字塔池化模块(PPM),将具有不同感受野的特征图进行融合,实现多级特征信息融合互补,提高特征表达能力。实验结果表明,改进算法在自制火焰数据集上的平均检测精度均值达到 84.3%,比原网络提高 4.1%。

**关键词:**火焰目标;YOLOv3-tiny 网络;金字塔池化模块;检测算法

中图分类号:TN929.5

文献标志码:A

## Flame object detection algorithm based on YOLOv3-tiny

XU Yan, LI Yongquan, GUO Xiaoyan, HAN Lisu, LIU Qiaoling

(College of Electronic Information Engineering, Shandong University of Science and Technology, Qingdao, Shandong 266590, China)

**Abstract:** To solve the problem of poor detection results on commonly used algorithms and fit the demand for real-time flame detection, a flame object detection algorithm based on the YOLOv3-tiny network was proposed in this paper. Firstly, the CSP-MobileNetV2 structure was constructed and introduced into the pooling layers of the backbone network to replace the original convolution layer, thus enhancing the feature extraction capability of the network. Secondly, the selective kernel network (SKNet) was introduced to make the convolution kernel adaptively adjust to flame objects of different sizes, thus enhancing the ability of extracting flame features. Thirdly, the pyramid pooling module (PPM) was introduced to fuse feature maps with different receptive fields, thus achieving multi-level feature information fusion and complementarity and improving the feature expression capability. The experiment results show that the mean accuracy precision of the improved algorithm on the self-made flame dataset reaches 84.3%, which is 4.1% higher than the original network.

**Key words:** flame object; YOLOv3-tiny network; PPM; detection algorithm

火灾是极具破坏性的灾害之一,造成的损失巨大,因此火灾的预防以及前期检测尤为重要。基于传感器的传统火灾检测系统存在检测条件单一、易受户外场景干扰、响应速度慢等缺陷。近年来基于深度学习算法的计算机视觉发展迅速,相比于传统机器学习算法与图像处理技术,深度学习具有强大的特征表示能力和自

收稿日期:2021-09-27

基金项目:山东省研究生教育优质课程项目(SDYKC19083);山东省研究生教育联合培养基地项目(SDYJD18027);青岛市社科规划研究项目(QDSKL1901120)

作者简介:徐 岩(1970—),男,山东汶上人,教授,博士生导师,主要从事计算机视觉、图像识别与信号处理等方面的研究。

E-mail:xly5@163.com

李永泉(1996—),男,山东潍坊人,硕士研究生,主要从事深度学习、目标检测等方面的研究,本文通信作者。

E-mail:2973296259@qq.com

主学习能力,将深度学习技术与火灾检测相结合,检测速度和精度可以大幅提升。

### 1 深度学习与火焰检测发展

基于深度学习的火焰检测主要是通过搭建卷积神经网络提取火焰特征进行分类识别,实现端到端的火焰检测。2016年 Frizzi 等<sup>[1]</sup>搭建 9 层卷积神经网络实现了对火焰和烟雾的分类,检测速度较快。Muhammad 等<sup>[2]</sup>使用 AlexNet<sup>[3]</sup>实现对火灾特征的提取,但网络参数量较大,泛化性较差。2018 年 Sun 等<sup>[4]</sup>利用残差结构设计了一个新的网络进行火焰识别,通过滑动窗口进行定位,取得较好的检测效果。同年, Yan 等<sup>[5]</sup>利用 Faster-RCNN<sup>[6]</sup>实现了火焰的端到端检测,检测速度与精度大幅提升。2021 年 Han 等<sup>[7]</sup>采用改进的 CA-SSD 网络检测吸烟行为,在保证实时性的基础上,提高了烟雾检测的准确性。

常用于目标检测的卷积神经网络模型主要分为两类,一类是以 R-CNN<sup>[8]</sup>系列为代表的两阶段模型,在检测过程中,首先找到目标候选区域<sup>[9]</sup>,然后对候选区域进行分类与定位,该类方案检测精度较高,但相对于单阶段网络检测速度较慢;另一类是以 YOLO 系列<sup>[10-13]</sup>、SSD<sup>[14]</sup>为代表的单阶段模型,将检测问题看成坐标回归问题,通过模型直接输出目标检测结果,该类算法检测速度较快,但相对于两阶段网络检测精度较差。本研究针对火焰检测实时性需求,选取 YOLOv3-tiny 轻量级网络。通过改进该网络,在保证检测速度的同时提高火焰检测的精度,并通过自制的火焰数据集进行实验,验证改进的 YOLOv3-tiny 算法的有效性。

### 2 YOLOv3-tiny 网络结构及改进

#### 2.1 YOLOv3-tiny 网络结构

YOLOv3-tiny 是 YOLOv3 的一个轻量级网络,构架分为特征提取网络、特征融合网络、检测网络 3 个部分。相比于 YOLOv3 采用残差结构来加深特征提取网络的方式,YOLOv3-tiny 骨干网络仅由卷积层和池化层简单堆叠构成,极大地降低了网络的参数量和计算量,提升了检测速度。特征融合部分延续了 YOLOv3 网络采用深层高语义特征图上采样与浅层特征图拼接的融合方式,实现深浅层特征信息的互补。检测网络部分删除了  $52 \times 52$  大小的检测分支,仅包含  $13 \times 13$ 、 $26 \times 26$  大小的两个预测分支。具体网络结构如图 1 所示,其中 Concat 表示特征图拼接操作, Upsample 表示上采样操作, Conv\_1、Conv\_2 分别表示  $3 \times 3$ 、 $1 \times 1$  卷积操作, P1、P2 表示输出特征图。




图 1 YOLOv3-tiny 网络结构

Fig. 1 Structure of YOLOv3-tiny network

#### 2.2 网络改进

##### 2.2.1 引入 CSP-MobileNetV2 模块替换骨干网络部分卷积层

YOLOv3-tiny 骨干网络通过卷积层提取特征,池化层降低维度,网络结构简单且层数较少,导致目标特征提取不充分,火焰检测效果较差。本研究在骨干网络相邻两个池化层之间引入 CSP-MobileNetV2 模块,替换骨干网络部分卷积层,从而增强网络的特征提取能力,使得深层输出特征图含有更丰富的语义信息。

CSPNet<sup>[15]</sup>模块通过对输入特征图进行二分支操作,将特征图分成相同的两个分支,其中一个分支进行后续的卷积激活操作,另外一个分支通过跨层连接与卷积激活后的分支进行通道拼接,实现特征融合。CSPNet 采用分支操作实现梯度流分割,通过跨层连接实现多种梯度信息组合,缓解网络训练过程中梯度重

复利用问题,降低计算量,提升网络的性能。

MobileNetV2<sup>[16]</sup> 模块由一个  $1 \times 1$  的点卷积和一个深度可分离卷积构成。由于深度卷积无法改变特征图通道数,学习到的特征数受输入通道的限制,因此,MobileNetV2 在深度可分离卷积结构之前添加了一个  $1 \times 1$  卷积进行通道升维,获取更多的目标特征。MobileNetV2 模块类似于倒置的残差模块,深度可分离卷积常用来替换普通卷积,减少参数数量和计算量。

本研究将 CSPNet 模块与 MobileNetV2 模块相结合,在满足检测速度的情况下提升了网络的检测性能。图 2 为 CSPNet 模块、MobileNetV2 模块以及融合后的 CSP-MobileNetV2 模块结构。

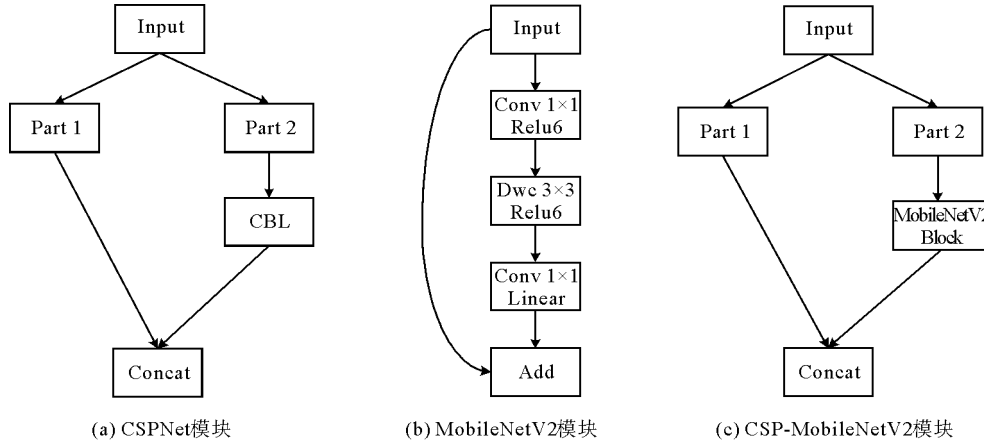


图 2 模块结构

Fig. 2 Module structure

### 2.2.2 引入 SKNet 选核注意力网络

火焰发生的场景复杂多样且火焰的形状大小各异,复杂的背景信息对火焰目标检测会产生干扰,同时不同尺度的火焰目标在同种大小卷积核的作用下提取的特征信息量差距较大,使得目标特征提取不充分。为了在提高对火焰有用信息关注的同时,使火焰特征提取更充分,本研究在原始网络检测分支输出之前引入选核注意力网络(selective kernel network, SKNet)<sup>[17]</sup>。SKNet 是 SENet<sup>[18]</sup> 的改进版,通过对不同大小的卷积核提取到的特征图进行全局池化、激活、加权等操作,加强特征图通道关联的同时实现不同分支特征图的加权分配。SKNet 的结构如图 3 所示,作用过程可分为 3 个部分。

1) 分支卷积。将输入特征图经过不同大小的卷积核进行卷积操作,得到具有不同感受野的特征图。分支卷积的个数可以有 2 个到多个。实验表明,在本研究数据集上分支卷积个数为 2 时检测效果最好,分支卷积的大小分别为  $3 \times 3$  和  $5 \times 5$ 。

2) 融合。将各卷积分支得到的特征图  $F_1$ 、 $F_2$  对应位置元素相加得到特征图  $X'$ ,其中  $F_1$ 、 $F_2$  以及融合特征图  $X'$  的维度与输入特征图尺寸一致,皆为  $H \times W \times C$  ( $H$ 、 $W$  为特征图的高度和宽度,  $C$  为通道数)。对特征图  $X'$  进行通道维度上的全局平均池化(global average pooling, GAP)得到维度为  $1 \times 1 \times C$  的特征图,再经过两个全连接层进行非线性变换。其中,第一个全连接层进行降维,将特征图降为  $1 \times 1 \times d$ ,第二个全连接层将特征图恢复到  $1 \times 1 \times C$ 。最后通过 softmax 函数激活得到两个  $1 \times 1 \times C$  的通道描述符  $a$  和  $b$ ,两个通道描述符对应位置的权重相加等于 1,实现不同卷积核输出特征图通道权重的分配。式(1)、(2)、(3)分别表示特征融合操作、全局池化操作、激活归一化操作。

$$X' = F_1 + F_2, \quad (1)$$

$$S_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X'_c(i, j), \quad (2)$$

$$Z = \delta(B(S)). \quad (3)$$

式(3)中,  $\delta$  表示 RELU 激活操作,  $B$  表示归一化操作。

3) 选择。将  $a$  和  $b$  分别与对应的特征图  $F1$ 、 $F2$  进行通道间相乘得到特征图  $F1'$  和  $F2'$ ，完成权重分配，将加权后的特征图进行逐元素相加得到最终的特征图  $V$ 。式(4)表示 Select 操作过程， $a_c$  表示权重图  $a$  中第  $c$  个元素， $b_c$ 、 $F1'_c$ 、 $F2'_c$  同理。

$$v_c = a_c \cdot F1'_c + b_c \cdot F2'_c, a_c + b_c = 1. \tag{4}$$




图3 选核注意力网络结构

Fig. 3 SKNet structure

### 2.2.3 插入 PPM 金字塔池化模块

通常网络越深感受野越大，而 YOLOv3-tiny 结构简单，网络层数少，得到的特征图感受野比较小，目标的检测效果不佳。通过加深网络来扩大感受野会增加网络的参数量和计算量，为了兼顾检测速度，同时扩大网络的感受野，捕获更丰富的多尺度上下文信息，提高网络的整体性能，本研究在骨干网络末端加入金字塔池化模块(pyramid pooling module, PPM)<sup>[19]</sup>。

PPM 通过对输入特征图进行一系列不同大小的池化操作得到具有不同感受野的特征图，将得到的特征图与输入特征图进行空间维度上的拼接融合，实现多级特征信息的融合互补。具体过程为：将输入特征图分别进行  $1 \times 1$ 、 $2 \times 2$ 、 $3 \times 3$ 、 $6 \times 6$  大小的池化操作，将池化后的特征图通过  $1 \times 1$  的卷积进行通道降维，通道数降为输入特征通道的  $1/N$  ( $N$  为池化操作个数)；将降维后的特征图采用双线性插值法，上采样得到输入特征图大小，然后与输入特征图进行空间维度上的拼接，使特征图通道数变为  $2C$ ；最后通过卷积操作将特征图进行特征融合降维，通道数恢复为  $C$ ，实现从全局到局部多尺度特征信息的充分利用。图 4 为 PPM 结构图，图 5 为改进的网络整体结构图，红色边框部分为改进的区域。

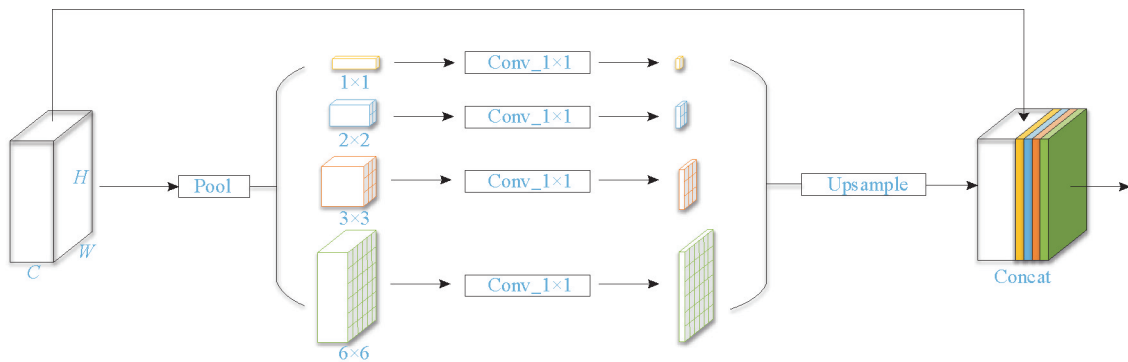


图4 金字塔池化模块结构

Fig. 4 Structure of PPM

## 3 实验

### 3.1 实验环境与数据集

实验环境为 Deepin Linux V20 系统、NVIDIA GeForce RTX 3080 GPU(10 GB)显卡等硬件条件，结合 Python 语言和 Pytorch 深度学习框架进行编程实现。输入图片大小为  $416 \times 416$ ，网络初始学习率为 0.001，权重

衰减系数为 0.000 5,采用动量梯度下降优化算法,动量值为 0.9,batch size 设置为 32,训练轮数(epoch)为 150。

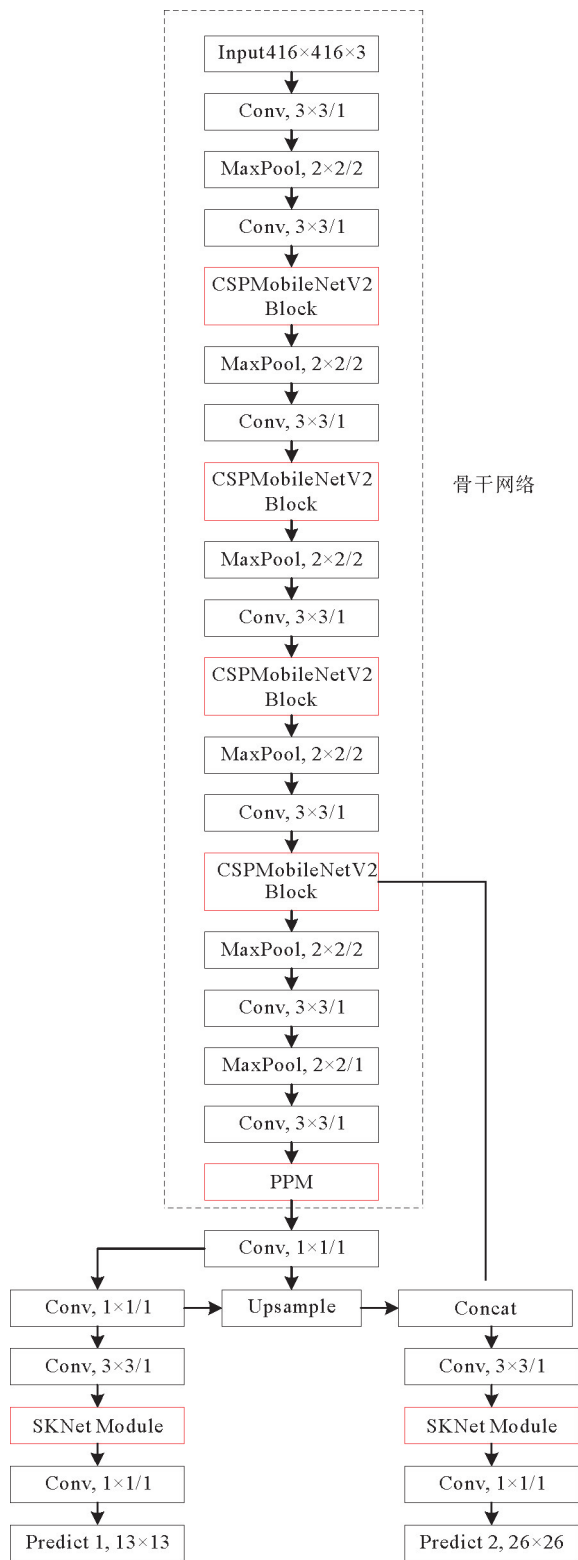


图 5 改进的网络结构

Fig. 5 Structure of the improved network

目前网络上公开的火焰数据集较少且质量不高。本研究通过网络爬虫技术自制火焰数据集,共 9 206 张图片,其中训练集 7 365 张,测试集 1 841 张,训练集图片和测试集图片比例为 8 : 2。通过 Labelimg 标注软件将数据集制作成 PASCAL VOC 格式。数据集图片分布比较广泛,既包含了烛火、火炬、篝火等燃烧稳定、特征明显的火焰,也包含了森林火灾、交通火灾、城市火灾等背景复杂、形状多样的火焰。由于数据集包含的背景复杂多样,火焰燃烧阶段不同且形状不一,检测难度较大。数据集中火焰图片大体可以分为两大类,如表 1 所示。

为了使锚框的大小更符合数据集的目标尺寸,本研究通过 K-means 聚类分析法<sup>[20]</sup>重新寻找合适的聚类中心生成适合本数据集的 6 个锚框,大小分别为(17, 23), (26, 46), (54, 59), (66, 115), (128, 145), (216, 279)。锚框尺寸整体符合自制数据集中目标框的尺寸分布,用来加速算法的训练。

### 3.2 评价指标

实验常用的评价指标为准确率( $P$ )、召回率( $R$ )、平均检测精度( $A$ )、平均精度均值( $m_{AP}$ )以及检测速度( $F_{ps}$ )。以下分别为几个指标的计算式:

$$P = \frac{T}{T + F_P}, \tag{1}$$

$$R = \frac{T}{T + F_N}, \tag{2}$$

$$A = \int_0^1 P dR, \tag{3}$$

$$m_{AP} = \frac{\sum_{i=1}^N A_i}{N}. \tag{4}$$

式中: $T$  为真正例,表示被预测为正类的正样本; $F_P$  为假正例,表示被预测为正类的负样本; $F_N$  为假负例,表示被预测为负类的正样本; $N$  为类别个数。本研究只有火焰一类,故采取的评价指标为  $m_{AP}$  和  $F_{ps}$ 。

### 3.3 实验结果与分析

本研究在原网络的基础上,分别对单一改进点、融合两个改进点以及最终网络进行了 8 个实验,具体实验结果如表 2 所示。

在本研究自制数据集上,YOLOv3-tiny 网络的  $m_{AP}$  为 80.2%,将 CSP-MobileNetV2 模块引入到骨干网络后  $m_{AP}$  提升 2.0%,表明引入 CSP-MobileNetV2 模块后网络的特征提取能力增强,对火焰的深度特征提取更充分。实验 3 为引入 PPM 后的网络性能,与原网络相比  $m_{AP}$  提升 1.5%,说明多级特征信息融合使火焰信息互补,检测效果更好。实验 4 为加入 SKNet 模块后的结果,网络的

$m_{AP}$  提升 1.8%,该结果表明 SKNet 模块实现了不同尺度火焰目标对卷积核的自适应选择,对火焰特征提取更充分。实验 5~7 分别将实验 2~4 进行两两融合,融合后的  $m_{AP}$  分别为 83.1%、83.4%、82.9%。实验 8 为本算法结果, $m_{AP}$  达到 84.3%,与 YOLOv3-tiny 网络相比, $m_{AP}$  提升了 4.1%,证明了本

表 1 数据集分类

Tab. 1 Dataset classification

种类	图片数量	锚框数量
森林火灾,交通火灾,城市火灾	7 430	12 103
烛火,火炬,火堆	1 776	2 604
总计	9 206	14 707

表 2 消融实验结果

Tab. 2 Results of ablation experiment

实验	Baseline	CSP-MobileNetV2	PPM 模块	SKNet 模块	$m_{AP}/\%$
1	✓	—	—	—	80.2
2	✓	✓	—	—	82.2
3	✓	—	✓	—	81.7
4	✓	—	—	✓	82.0
5	✓	✓	✓	—	83.1
6	✓	✓	—	✓	83.4
7	✓	—	✓	✓	82.9
8	✓	✓	✓	✓	84.3

算法的有效性。

图 6 为实验 1 与实验 8 训练过程中平均精度均值曲线对比图。从图 6 可以看出,随着训练程度的加深两条曲线呈上升趋势,并在 100 轮左右趋于稳定。最终 YOLOv3-tiny 的  $m_{AP}$  为 80.2%,本算法的  $m_{AP}$  达到 84.3%,整体提升了 4.1%。

为了进一步验证本算法的有效性,分别从检测精度与检测速度两个方面对比几种常用算法在本研究自制数据集上的表现,结果见表 3。

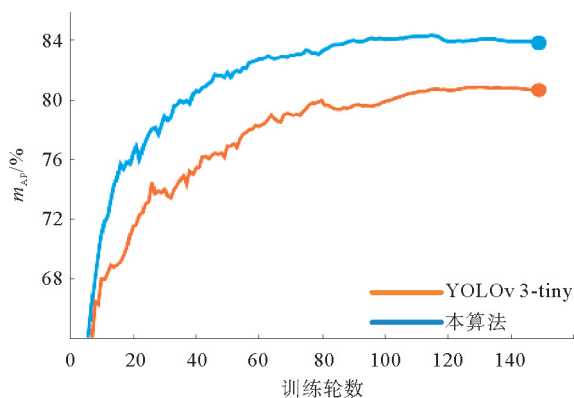


图 6 实验曲线

Fig. 6 Experimental curve

表 3 不同算法实验对比

Tab. 3 Comparison of different algorithm experiments

算法	$m_{AP}/\%$	$F_{ps}$
YOLOv3	83.5	53
SSD	72.1	42
YOLOv3-tiny	80.2	177
YOLOv4-tiny	66.1	200
YOLOv5m	82.7	37
YOLOv5l	81.8	30
EfficientDet-D2	77.3	60
本算法	84.3	106

如表 3 所示,在检测精度上,本算法的平均精度均值最高,达到 84.3%。与 YOLOv3、YOLOv3-tiny、EfficientDet-D2<sup>[21]</sup> 和 YOLOv5m 相比分别提高了 0.8%、4.1%、7.0% 和 1.6%。

在检测速度方面,本算法的  $F_{ps}$  为 106,相较于 YOLOv3、SSD,  $F_{ps}$  分别高出 53 和 64,比 YOLOv5m、EfficientDet-D2 算法分别高出 69 和 46。由于引入模块带来少许的参数量和计算量增加,所以与 YOLOv3-tiny、YOLOv4-tiny 相比,速度稍微降低,但检测速度依旧满足实时性检测的需求。

图 7 为 YOLOv3-tiny 算法与本算法在训练过程中分类损失与回归损失的对比曲线,图 7(a)、7(b)分别表示回归损失和分类损失。

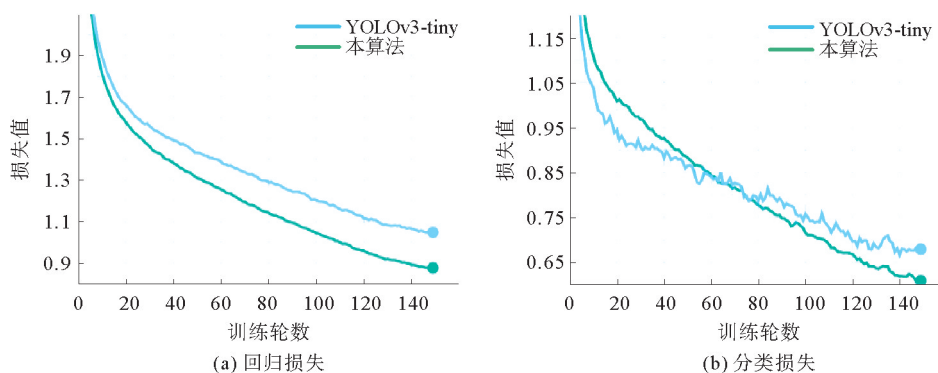


图 7 损失曲线

Fig. 7 Loss curve

在图 7 中,改进前后算法损失曲线都呈下降趋势。随着训练程度的加深,原算法的回归损失值与分类损失值最终分别稳定在 1.1 与 0.7 左右,本算法的回归损失值与分类损失值最终分别稳定在 0.9 与 0.6 左右。

为对比改进前后算法的检测效果,对部分火焰图片进行测试。测试的火灾类型包括夜间城市火灾、森林火灾、汽车起火 3 种类型。图 8(a)为 YOLOv3-tiny 算法的检测结果,图 8(b)为本算法的检测结果。通过检测结果看出,本算法的检测效果整体有所提升,且对原算法漏检的小火焰也有较好的检测效果。

表 4 为模型改进前后的参数数量和训练时间对比。从表 4 中可以看出,由于 CSP-MobileNetV2、SKNet 以及 PPM 等模块的加入,改进后 YOLOv3-tiny 算法的参数数量上升 4.5M,导致算法运行时间有所提高,算法处理一张图片的时间为 9.4 ms,比原 YOLOv3-tiny 增加 3.8 ms。

#### 4 结论

本研究提出一种基于 YOLOv3-tiny 的轻量级火焰检测算法,并利用自制的火焰数据集验证了算法的有效性。通过在骨干网络中加入 CSP-MobileNetV2 结构,提升了算法对火焰目标的特征提取能力;在检测分支输出前加入 SKNet,加强了对重要特征的关注,实现了不同尺度火焰目标自主选择合适的卷积核;在骨干网络末端加入 PPM,实现了多尺度火焰目标特征融合互补,提升了火焰的检测效果。实验结果表明,本算法在自制火焰数据集上相比于原算法,  $m_{AP}$  提高了 4.1%,  $F_{ps}$  为 106,检测效果显著提升。

由于自制的火焰数据集图片数量不够充足,后续需要进一步扩充数据集图片,同时本算法的检测速度只是通过部分样本图片推理计算得出,并未在实际应用中进行测试,且网络训练时间较长,在实验配置上过度依赖高算力的 GPU,距离实际的实时检测还有差距。在后续工作中,需要进一步开展实验验证,在不降低准确率的前提下,研究如何缩短算法训练时间。

#### 参考文献:

[1]FRIZZI S,KAABI R,BOUCHOUICHA M,et al.Convolutional neural network for video fire and smoke detection[C]//42nd Annual Conference of the IEEE Industrial Electronics Society.Florence,Oct. 23-26,2016:877-882.

[2]MUHAMMAD K,AHMAD J,BAIK S W.Early fire detection using convolutional neural networks during surveillance for effective disaster management[J].Neurocomputing,2018,288:30-42.

[3]KRIZHEVSKY A,SUTSKEVER I,HINTON G.ImageNet classification with deep convolutional neural networks[J].Communications of the ACM,2017,60(6):84-90.

[4]孙琛.基于视频图像的火灾检测算法研究与设计[D].济南:山东大学,2018.

SUN Chen.Research and design of fire detection algorithm based on video image[D].Jinan:Shandong University,2018.

[5]严云洋,朱晓妤,刘以安,等.基于 Faster R-CNN 模型的火焰检测[J].南京师大学报(自然科学版),2018,41(3):1-5.

YAN Yunyang,ZHU Xiaoyu,LIU Yi'an,et al.Flame detection based on Faster R-CNN model[J].Journal of Nanjing Normal University(Natural Science Edition),2018,41(3):1-5.

[6]REN S Q,HE K M,GIRSHICK R,et al.Faster R-CNN:Towards real-time object detection with region proposal networks [J].IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(6):1137-1149.

[7]HAN L,RONG L L,LI Y Q,et al.CA-SSD-Based real-time smoking target detection algorithm[C]//5th International Conference on Digital Signal Processing. Chengdu, Feb. 26-28,2021:283-288.

[8]GIRSHICK R.Fast R-CNN[C]//IEEE International Conference on Computer Vision.Santiago,Dec. 7-13,2015:1440-1448.



(a) YOLOv3-tiny (b) 本算法

图 8 部分火焰检测图片

Fig. 8 Detection pictures of part of the fire

表 4 算法参数数量及运行时间对比

Tab. 4 Comparison of algorithm parameters and running time

算法	参数数量/M	运行时间/ms
YOLOv3-tiny	8.7	5.6
改进 YOLOv3-tiny	13.2	9.4



- [9] KONG T, YAO A B, CHEN Y R, et al. HyperNet: Towards accurate region proposal generation and joint object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, Jun. 27-30, 2016: 845-853.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified real-time object detection [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, Jun. 27-30, 2016: 779-788.
- [11] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Hawaii, Jul. 21-26, 2017: 6517-6525.
- [12] ZHAO L Q, LI S Y. Object detection algorithm based on improved YOLOv3 [J/OL]. Electronics, 2020, 9(3). DOI: 10.3390/electronics9030537.
- [13] CAO C Z, TAN X Y, HUANG X Y, et al. Study of flame detection based on improved YOLOv4 [C/OL]// Journal of Physics Conference Series. Dalian, Apr. 14-16, 2021, 1952(2). DOI: 10.1088/1742-6596/1952/2/022016.
- [14] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]// European Conference on Computer Vision. Amsterdam, Dec. 8-16, 2016: 21-37.
- [15] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle, Jun. 13-19, 2020: 390-391.
- [16] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]// IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Jun. 18-23, 2018: 4510-4520.
- [17] LI X, WANG W L, HU X L, et al. Selective kernel networks [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Lang Beach, Jun. 15-20, 2019: 510-519.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Jun. 18-23, 2018: 7132-7141.
- [19] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]// IEEE Conference on Computer Vision and Pattern Recognition. Hawaii, Jul. 21-26, 2017: 2881-2890.
- [20] KRISHNA K, MURTY M N. Genetic K-means algorithm [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 1999, 29(3): 433-439.
- [21] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, Jun. 13-19, 2020: 10778-10787.

(责任编辑:傅 游)