

基于定位置信度和区域全卷积网络的火焰检测方法

张鸿^{1,2}, 严云洋^{1,2*}, 刘以安¹, 高尚兵²

¹江南大学物联网工程学院, 江苏 无锡 214122;

²淮阴工学院计算机与软件工程学院, 江苏 淮安 223003

摘要 针对火焰检测定位精度与检测精度不高的问题,提出了基于定位置信度和区域全卷积网络的火焰检测方法。首先使用扩大的可分离卷积提高感受野,减少模型参数量,提高检测速度;其次对预测候选框进行平移和伸缩操作,以提高候选区域的完整性;然后对非极大值抑制方法采用分类置信度作为排序标准,而导致的错误抑制问题,引入定位置信度,以提高候选框的定位精度及检测精度;最后加入新的标签,分别代表特征不明显的弱火焰与特征明显的强火焰,对弱火焰样本加强学习,使得弱火焰能与亮色背景更好区分,从而降低样本漏检率。实验结果表明,本文方法在 Bilkent 大学公开火焰数据集以及互联网搜集的测试数据上,检测的火焰区域更完整,火焰位置更精确,火焰检测率更高。

关键词 图像处理; 火焰检测; 区域全卷积网络; 可分离卷积; 定位置信度; 非极大值抑制

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP57.201021

Fire Detection Method Based on Localization Confidence and Region-Based Fully Convolutional Network

Zhang Hong^{1,2}, Yan Yunyang^{1,2*}, Liu Yian¹, Gao Shangbing²

¹ School of Internet of Things Engineering, Jiangnan University, Wuxi, Jiangsu 214122, China;

² Faculty of Computer & Software Engineering, Huaiyin Institute of Technology, Huaian, Jiangsu 223003, China

Abstract Aiming at the problem of low location accuracy and detection accuracy of fire detection, a fire detection method based on localization confidence and region-based fully convolutional network is proposed. First, expanded separable convolutions are used to improve the receptive field, reduce the amount of model parameters, and improve the detection speed. Second, the prediction candidate frame is translated and stretched to improve the integrity of the candidate region. Then, for non-maximum suppression method, the classification confidence degree is used as a sorting standard, which leads to the error suppression problem, so as to improve the location accuracy and detection accuracy of the candidate frame. Finally, new tags are added, they represent the weak fire with no obvious characteristics and the strong fire with obvious characteristics, respectively. The weak fire samples are strengthened to distinguish the weak fire from the bright background, so as to reduce the sample missing rate. Experimental results show that the proposed method, based on the public fire data set of Bilkent University and the test data collected from the internet, can make the fire area detected to be more complete. The fire position is more accurate, and the fire detection rate is higher.

Key words image processing; fire detection; region-based fully convolutional network; separable convolutions; localization confidence; non-maximum suppression

OCIS codes 100.4999; 100.4996; 100.3008

收稿日期: 2020-02-12; 修回日期: 2020-02-23; 录用日期: 2020-03-12

基金项目: 国家自然科学基金(61402192)、江苏省“六大人才高峰”项目(2013DZXX-023)、江苏省高校自然科学基金重大项目(18KJA52001)、江苏省“青蓝工程”、淮安市“533 英才工程”、淮安市自然科学课题(HAB201803)

* E-mail: yunyang@hyit.edu.cn

1 引言

火灾是一种破坏力巨大的多发性灾害,每年给自然界及人类社会带来巨大损失^[1-2]。因此构建一种高效率、高检出率的火焰检测方法对火灾预防具有重要意义^[3],基于深度卷积网络的火焰检测方法成为了当前研究热点。

基于深度卷积网络的主流火焰检测方法可以分为两类,单步检测器方法与双步检测器方法。以 SSD^[4]和 YOLO^[5]系列为代表的单步检测器方法将候选框位置及分类信息融合在一个网络中,通过卷积核获得类别分数及候选框偏差。杜晨锡等^[6]提出一种基于 YOLOv2 的火焰检测方法,使用多尺度融合方法提高模型检测效果,检测速度达到了实时性要求,但对小目标检测效果较差。Wu 等^[7]分别使用 Faster R-CNN、YOLO 与 SSD 对火焰进行识别,实验对比结果说明 SSD 的实时性更好,同时又提出了一种基于微调的 tiny-yolo-voc1 网络,得到了更好的检测速度与精度。单步检测器虽然获得了检测速度的提升,但将候选框位置及分类放在一个网络中计算,检测精度不如双步检测器方法。

以区域卷积神经网络(RCNN)为代表的双步检测器方法通过滑动窗口获得候选框位置,以及通过池化获得分类分数这两个步骤实现火焰检测,更适合对检测精度有较高要求的火焰检测。回天等^[8]提出一种基于 Faster-RCNN 网络并融合多类型火焰的检测方法,在复杂背景以及不同光照情况下都有较好的检测效果,但检测速度较慢。洪伟等^[9]基于

区域全卷积网络(R-FCN)方法并使用残差网络进行二次分类,提高火焰检测精度,但二次分类使得检测速度下降。双步检测器方法中 Faster-RCNN、Fast-RCNN 等检测速度较慢,因此选择检测速度较快的 R-FCN 方法检测火焰。此外,双步检测器方法大多基于区域建议网络(RPN)^[10],但 RPN 对候选框的选择采用分类置信度作为排序依据,在训练过程中会令定位效果更好的候选框被错误删除。

因此,本文引入定位置信度^[11]替换分类置信度,同时通过平移伸缩变换和精准池化等操作进一步提升检测精度。并使用可分离卷积减少参数计算量,提高检测速度。实验中发现,在自制火焰训练集中添加弱火焰(L-Fire)与强火焰(S-Fire)标签,可以有效降低特征不明显而背景强烈的火焰漏检率,增强检测性能。实验结果表明,所提出的基于定位置信度和区域全卷积网络的方法,在用于静态及动态火焰检测时,漏检率都较低,且检测速度较快。

2 区域全卷积网络

2.1 区域全卷积网络框架

如图 1 所示,区域全卷积网络(R-FCN)检测步骤为:1)利用残差网络(ResNet)对输入图像进行卷积操作生成特征图;2)RPN 与敏感位置卷积池化网络共享特征图,其中 RPN 通过滑动窗口处理特征图得到疑似目标区域集合(ROIS),敏感位置卷积池化通过平均池化处理特征图得到分类分数;3)融合位置及分类信息通过分类器分类识别。




图 1 R-FCN 检测图

Fig. 1 Detection diagram of R-FCN

特征图卷积操作可以表示为

$$Z^{l+1}(i, j) = [Z^l \otimes w^{l+1}](i, j) + b = \sum_{k=1}^{C_l} \sum_{x=1}^k \sum_{y=1}^k [Z_c^l(s_0 i + x, s_0 j + y) w_c^{l+1}(x, y)] + b, \quad (1)$$

式中: Z^l 和 Z^{l+1} 表示第 $l+1$ 层卷积层的输入和输出特征图; w 表示变换参数; (i, j) 表示 $l+1$ 层特征图像素点; (x, y) 表示 l 层特征图像素点; c 表示特征图通道; k 表示卷积核大小; s_0 表示卷积步长; b 表示偏差量。

池化操作可以表示为

$$A_c^l(i, j) = \left[\sum_{x=1}^k \sum_{y=1}^k A_k^l(s_0 i + x, s_0 j + y)^t \right]^{\frac{1}{t}}, \quad (2)$$

式中: A_k^l 表示通道数为 k 的特征图在第 l 层经池化操作后的输出; t 为参数, 当 $t=1$ 时, 表示平均池化, 其余变量与(1)式含义相同。

R-FCN 网络分类表示为

$$O_{\text{output}} = P_{\text{pic}} \cdot Z \cdot \left\{ A(t=1) \right\} \cdot S_{\text{softmax}}, \quad (3)$$

式中: \cdot 表示网络连接; P_{pic} 表示待检测的火焰图片; Z 表示经过卷积处理后输出的特征图; R_{ROIS} 表示经过 RPN 处理得到的疑似火焰区域集合; $A(t=1)$ 表示平均池化操作得到每个疑似火焰区域的分类分数; S_{softmax} 表示分类器。经过分类器处理后的输出分类分数为

$$s_j = \frac{\exp[x(j)]}{\sum_{j=1}^N \exp[x(j)]}, \quad (4)$$

式中: $x(j)$ 表示池化得到的第 j 个候选框的分类分数。

2.2 残差网络

区域全卷积网络采用 ResNet-101 的残差网络结构, 残差网络是一种通过在输入与输出之间建立关联通道, 使有参层学习输入与输出之间残差项的网络。数学表达式为

$$H(x) = F(x) + x, \quad (5)$$

式中: $H(x)$ 表示输出; $F(x)$ 表示残差项; x 表示输入值。

在残差网络中, R-FCN 使用大小为 7×7 的卷积核获得特征图像, 通过大量实验, 本文将其修改为 13×13 , 共获得约 3.5 倍的感受野 ($13^2/7^2$)。此时 R-FCN 模型参数量约为 $2048 \times 13 \times 13 \times 2 \times 7 \times 7 \approx 3.39 \times 10^7$, 由参数量计算公式获得。

$$N = c \times k \times C_{\text{cls}} \times p, \quad (6)$$

式中: N 表示模型参数量; c 表示特征图通道数; k 表示卷积核大小; C_{cls} 表示检测目标分类; p 表示池化核大小。

将 13×13 的卷积核拆分为 13×1 与 1×13 的可分离卷积核^[12], 此时模型参数量约为 $(13 \times 1 \times 2048 \times 256 + 1 \times 13 \times 256 \times 2 \times 7 \times 7) + (1 \times 13 \times 2048 \times 256 + 13 \times 1 \times 256 \times 2 \times 7 \times 7) \approx 1.43 \times 10^7$, 由参数量计算公式获得。

$$N = (k_1 \times c_1 \times c_2 + k_2 \times c_2 \times C_{\text{cls}} \times p) + (k_2 \times c_1 \times c_2 + k_1 \times c_2 \times C_{\text{cls}} \times p), \quad (7)$$

式中: k_1, k_2 表示可分离卷积核大小; c_1 表示输入图像通道; c_2 表示可分离卷积变换使用其他卷积核时的图像通道。

如图 2 所示, 可分离卷积使用 256 个 13×1 与 256 个 1×13 的卷积核处理输入的 2048 维图像, 得到 256 维的特征图, 再对应使用 1×13 与 13×1 的卷积核处理, 最终融合得到输出特征图。




图 2 可分离卷积

Fig. 2 Separable convolution

加入可分离卷积后, 模型参数量为原来的 0.4 ($1.43 \times 10^7/3.39 \times 10^7$), 在有效提高感受野的同时提高了检测速度。

但使用可分离卷积使检测精度略微下降, 因为可分离卷积缺少特征图空间维度的关联性, 使用可分离卷积主要目的是提高模型检测速度, 使其达到实时检测需求, 检测精度由后续工作提高。可分离卷积速度对比如表 1 所示。

表 1 检测速度对比

Table 1 Comparison of the speed of the detection

Method	Kernel	Speed / (frame/s)	Accuracy / %
R-FCN	13×13	15	96.9
Separable convolution	$13 \times 1, 1 \times 13$	22	96.4

2.3 区域建议网络

如图 3 所示, 在模型训练过程中, 真实候选框为

标记的火焰目标,原始候选框为检测到的火焰目标。虽然原始候选框提取到了火焰信息,但与真实候选框的交并比(IOU)小于阈值 0.5,在训练过程中会认为该候选框未检测到火焰信息,导致训练的模型检测效果不佳。




图 3 候选框标记信息不完整

Fig. 3 Incomplete information marked by anchors




图 4 平移伸缩变换

Fig. 4 Change of translation and scaling

因此,为了使原始候选框中非火焰区域尽可能减少^[13],更接近真实候选框。图 4 所示对原始候选框进行平移和伸缩操作,得到更接近真实候选框的预测候选框,增加 IOU,提高模型训练效果。IOU 计算公式为

$$O_{\text{IOU}} = \frac{P_{\text{Result}} \cap G_{\text{Result}}}{P_{\text{Result}} \cup G_{\text{Result}}}, \quad (8)$$

式中: $P_{\text{Result}} \cap G_{\text{Result}}$ 表示预测候选框与标注真实候选框之间重合区域的面积; $P_{\text{Result}} \cup G_{\text{Result}}$ 表示预测候选框与真实候选框面积之和减去重叠区域的面积; O_{IOU} 值域为 $[0, 1]$ 。

定义 P_x, P_y, P_w, P_h 分别表示预测候选框中心点的横纵坐标以及预测候选框的宽高。定义 O_x, O_y, O_w, O_h 分别表示原始候选框中心点的横纵坐标以及原始候选框的宽高,

$$\begin{cases} P_x = O_w d_x(P) + O_x \\ P_y = O_h d_y(P) + O_y \\ P_w = O_w \exp[d_w(P)] \\ P_h = O_h \exp[d_h(P)] \end{cases}, \quad (9)$$

式中: $d_x(P), d_y(P), d_w(P), d_h(P)$ 分别表示原始候选框横坐标、纵坐标、宽度、高度得到预测候选框的变换值。

定义原始候选框经过变换得到真实候选框需要经过的平移横量、纵量以及伸缩宽度、高度尺度分别为 t_x, t_y, t_w, t_h , 对应向量方向由变换方向决定,

$$\begin{cases} t_x = \frac{G_x - O_x}{O_w} \\ t_y = \frac{G_y - O_y}{O_h} \\ t_w = \ln \frac{G_w}{O_w} \\ t_h = \ln \frac{G_h}{O_h} \end{cases}, \quad (10)$$

式中: G_x, G_y, G_w, G_h 表示真实候选框中心点的横坐标和纵坐标,以及真实候选框的宽度和高度。使预测平移伸缩变换值与真实值尽量接近,得到损失函数,

$$O_{\text{Loss}} = \sum_i^{N_{\text{nu}}} [t_*^i - w_* \varphi(O_*^i)]^2 = \sum_i^{N_{\text{nu}}} [t_*^i - d_*(P)]^2. \quad (11)$$

损失函数由所有真实的平移伸缩变量与训练学习的变换量做差求平方后获得, w_* 是需要学习的变换参数; $\varphi(O_*^i)$ 表示真实候选框的特征量; $*$ 表示 (x, y, w, h) , 分别代表横轴、纵轴、宽度、高度,如 t_x 表示候选框在横轴上的变量; i 用于计数,下限为 1,上限为 N_{nu} ; N_{nu} 表示标定候选框总个数。利用损失函数得到最优变换参数,即优化目标为使损失函数最小,解得预测平移伸缩变换值,平移伸缩变换算法描述如下。

- 1) 输入原始候选框信息 O_x, O_y, O_w, O_h 和真实候选框信息 G_x, G_y, G_w, G_h ;
- 2) 通过计算(10)式得到所有候选框对应的真实变换量 t_x, t_y, t_w, t_h ;
- 3) 通过计算(11)式得到损失率 O_{Loss} ;
- 4) 训练损失函数,学习最优变换参数 w_* ;
- 5) 通过计算 $w_* \varphi(O_*^i) = d_*(P)$, 得到预测平移伸缩变换值 $d_x(P), d_y(P), d_w(P), d_h(P)$;
- 6) 将预测平移伸缩变换值及输入的第 n (初始值为 1) 个原始候选框信息代入(9)式,获得对应预

测候选框中心点横坐标、纵坐标以及预测候选框宽、高 P_x, P_y, P_w, P_h ;

7)判断未经过平移伸缩变换的原始候选框个数是否为0,若是,则跳转步骤8,否则跳转步骤6,令 $n = n + 1$,计算下一个预测候选框信息;

8)输出所有预测候选框。

2.4 敏感位置卷积池化

在敏感位置卷积池化中,R-FCN 采取的坐标取整量化处理会带来误差,导致检测精度下降,如图 5 所示。




图 5 迭代精度变化对比^[11]。(a) FPN 迭代精度变化;(b) R-CNN 迭代精度变化

Fig. 5 Comparison of iterations accuracy changes^[11]. (a) FPN iterations accuracy changes; (b) R-CNN iterations accuracy changes

图 5(a)中随着迭代次数增加,使用 FPN 方法检测目标时,检测精度上升之后急剧下降,而图 5(b)中使用 R-CNN 方法时,检测精度也是上升后缓慢下降,FPN 与 R-CNN 在池化中都采用了取整量化操作。

通过引入 IoU-Net^[11]网络中的精准池化层改进坐标取整量化误差,使用连续特征图计算二阶积分得到特征图内部特征,避免量化产生的误差。如图 6 所示,虚线表示真实候选框,传统池化通过取整操作获得实线表示的候选框,而精准池化将候选框区域视为连续,因此候选框内非已知离散点位置(图 6 内阴影空白部分),都可通过已知离散点求积分获得。




图 6 池化对比。(a) ROI 池化层;(b)精准 ROI 池化层

Fig. 6 Comparison of pooling. (a) ROI pooling; (b) precise ROI pooling

假设特征图上任意离散点 (i, j) ,特征为 $w_{i,j}$,使用双线性插值处理离散点,得到在任意连续坐标 (x, y) 处都连续的特征图(图 6 中阴影区域),表示为

$$f(x, y) = \sum_{i,j} C_{ic}(x, y, i, j)w_{i,j}, \quad (12)$$

式中: $f(x, y)$ 表示经过变换得到的特征图。 $C_{ic}(x, y, i, j)$ 为插值系数,表示为

$$C_{ic}(x, y, i, j) =$$

$$\max(0, 1 - |x - i|)\max(0, 1 - |y - j|). \quad (13)$$

将 ROI 中候选框记为 $B_{bin}, B_{bin} = \{(x_1, y_1), (x_2, y_2)\}$, (x_1, y_1) 和 (x_2, y_2) 分别表示候选框左上角与右下角坐标。最后对特征图内坐标做二阶积分,减少特征和参数。通过离散点求和获得近似积分结果后求取平均值,获得精准池化后的特征图内部特征。

$$O_{PrPoi}(B_{bin}, F) = \frac{\sum_{x=x_1}^{x_2} \sum_{y=y_1}^{y_2} f(x, y)}{(x_2 - x_1)(y_2 - y_1)}, \quad (14)$$

式中: F 表示输入的特征图像。

3 定位置信度计算

对经过区域建议网络和敏感卷积池化操作得到的候选框使用非极大值抑制(NMS)方法。即将候选框按得分排序,选择最高分候选框,然后遍历其他候选框^[14],判断与最高分候选框重叠率是否大于阈值。如果大于,则认为检测到同一目标,将该候选框删除;如果小于,则认为检测到不同目标,保留候选框,重复操作。如图 7 所示,实验中,得分为 0.83 和 0.74 的候选框重叠率为 0.78,大于阈值 0.5,判断检测到同一物体,删除得分较低候选框。




图 7 非极大值抑制

Fig. 7 Non-maximum suppression




图 8 NMS 定位置信度缺失

Fig. 8 Lack of localization confidence of NMS

非极大值抑制方法表示为

$$\begin{cases} n^i > W, \text{ delete } n^i, i++ \\ n^i \leq W, i++ \end{cases}, \quad (15)$$

式中： n 表示第 i 个候选框得分； W 表示阈值。

分类置信度与定位置信度都可以作为非极大值抑制方法的排序依据。R-FCN 使用分类置信度作




图 9 IOU 预测

Fig. 9 Prediction of IOU

定位置信度算法描述如下。

1) 输入 RPN 预测得到的候选框 IOU 和敏感位置卷积池化预测得到的区域分类分数；

2) 判断预测的第 n (初始值为 1) 个候选框区域分类分数是否大于 0, 若大于 0, 则 $P_{\text{object}} = 1$, 否则, $P_{\text{object}} = 0$;

3) 通过计算 (17) 式, 得到候选框定位置信度；

为排序依据, 使得如图 8 所示定位效果更好的候选框在抑制过程中被效果不好的候选框抑制。因此, 本文使用定位置信度作为排序依据, 以保留定位效果更好的候选框。

分类置信度表示分类情况, 由敏感位置卷积池化网络预测概率获得,

$$C_{\text{Cls}} = \frac{P(i)}{\sum_{i=1}^{N_{\text{num}}} P(i)}, \quad (16)$$

式中： C_{Cls} 表示分类置信度； $P(i)$ 表示属于 i 的类别概率； N_{num} 表示所有类别数目个数。

定位置信度表示候选框的定位效果, 由 O_{IOU} 与 P_{object} 相乘获得, 当预测候选框检测到目标时, 定位置信度取值等于 O_{IOU} ；当预测候选框未检测到目标时, 定位置信度取值为 0。

$$O_{\text{Loc}} = P_{\text{object}} \times O_{\text{IOU}}, \quad (17)$$

式中： O_{Loc} 表示分类置信度； O_{IOU} 由区域建议网络计算获得, 表示交并比； P_{object} 为精准池化, 根据分类分数判断预测候选框内是否有检测目标获得, 若预测候选框内有检测目标, 则取值为 1, 否则, 为 0。

通过如图 9 所示网络预测获得定位置信度。在训练阶段, 如区域建议网络一节, RPN 获得预测候选框位置信息, 计算预测候选框与真实候选框的 IOU。如敏感位置卷积池化一节, 精准池化处理特征图获得分类分数, 判断预测候选框内是否有检测目标。最后通过全连接融合候选框位置信息与分类信息, 计算获得定位置信度。获得定位置信度后, 通过非极大值抑制方法删除多余候选框, 保留有效候选框, 最后输出带有保留候选框的火焰图片。

4) 判断未计算定位置信度候选框个数是否为 0, 若是, 则跳转步骤 5, 否则, 跳转步骤 2, 令 $n = n + 1$, 计算下一个候选框的定位置信度；

5) 输出所有候选框对应定位置信度 O_{Loc} 。

4 基于定位置信度和区域全卷积网络的火焰检测方法

本文对 R-FCN 中的三个网络部分, 残差网络、

区域建议网络和敏感位置卷积池化网络进行改进,并引入定位置信度,提出基于定位置信度和区域全

卷积网络(LOF-FCN)的火焰检测方法,检测流程图 10 所示。

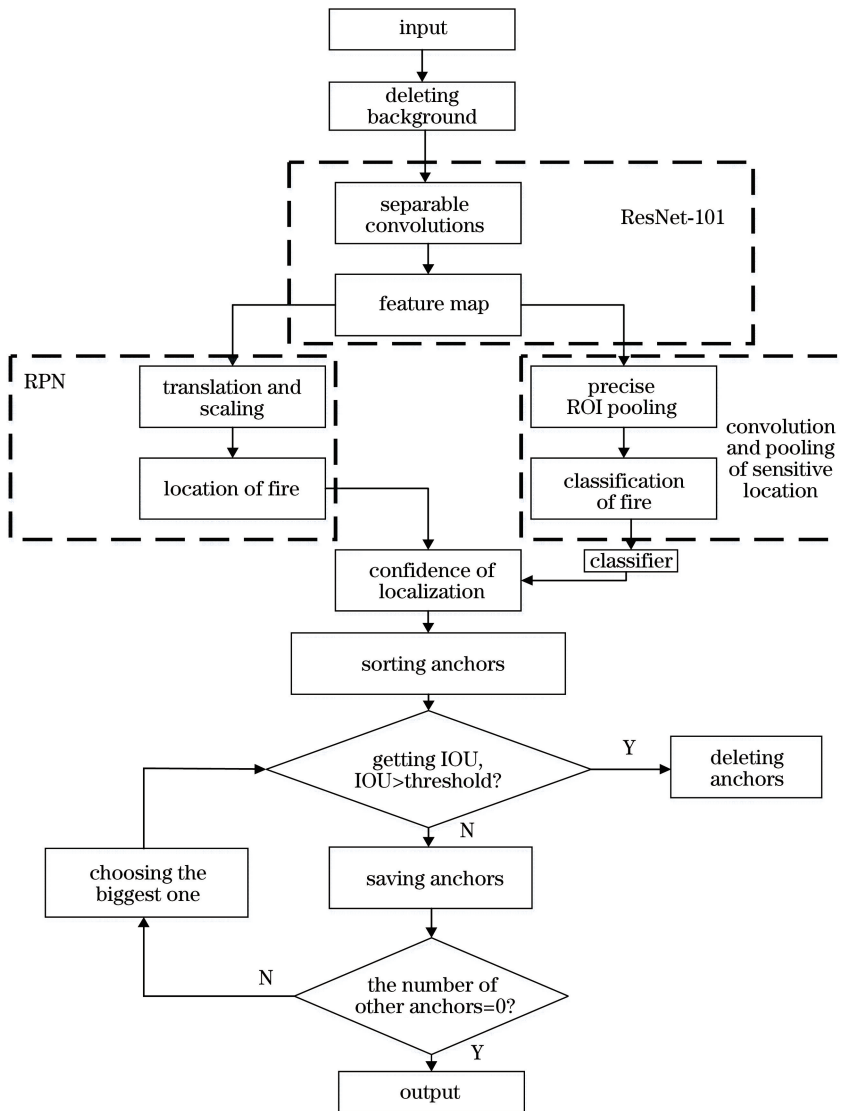


图 10 LOF-FCN 流程图

Fig. 10 Flow chart of LOF-FCN

对应火焰检测方法的算法描述如下。

- 1) 输入待检测火焰图片;
- 2) 使用可分离卷积处理图片,得到公共特征图;
- 3) 使用两个 1×1 的卷积核处理特征图,得到候选框前后景分数及候选框位置信息;
- 4) 删除得分为背景的候选框;
- 5) 使用伸缩变换算法训练获得的预测变换值,更新候选框;
- 6) 使用精准池化操作处理公共特征图,并通过分类器得到每个区域的分类得分;
- 7) 融合步骤 5 与步骤 6 输出信息;
- 8) 使用定位置信度计算方法,得到定位置信度;

- 9) 按定位置信度由大到小排序候选框;

10) 选择定位置信度最大的候选框作为被比较对象,并将定位置信度小于该候选框的分别与其计算 IOU;

11) 判断 IOU 与阈值大小,若 IOU 大于阈值,则删除比较候选框,否则,保留候选框;

12) 判断保留候选框中未作为被比较对象的候选框数量是否为 0,若是,则跳转步骤 14,否则,跳转步骤 13;

13) 选择保留候选框中未作为被比较对象且定位置信度最大的候选框作为新的被比较对象,跳转步骤 10;

14)输出火焰图片及保留候选框。

5 实验结果分析

5.1 火焰数据集建立

搜集 Bilkent 大学公开火焰数据库以及互联网视频网站火焰视频,将部分视频逐帧转换为图片格式,按顺序命名后保存构成 FireData 训练集,将其余部分保留视频格式构成 VisiData 测试集。FireData 训练集与 VisiData 测试集均包含火灾早期、火灾蔓延、实验室酒精灯、室内纸张燃烧以及点火器等不同燃烧场景。搜集到的火焰视频中具有较强颜色易区分的火焰样本(本文称为强火焰)数量占比较大;而火焰颜色较淡,背景颜色较强,体积较小的火焰样本(本文称为弱火焰)数量占比较小。导致训练好的模型在 VisiData 测试集上测试时,对强火焰具有偏向性,弱火焰存在较大漏检率。

为了提高弱火焰的检测精度,通过 LabelImage 工具手动为 FireData 训练集中的火焰添加 L-Fire 与 S-Fire 标签,构成新的 FireData 训练集,数据描述如表 2 所示。

表 2 训练数据
Table 2 Training data

Category	Picture	Number
L-Fire	1223	2104
S-Fire	3512	5921
Total	4735	8025

分别使用 R-FCN 及本文提出的 LOF-FCN 方法在添加标签与不添加标签的 FireData 训练集上训练模型,并在 VisiData 测试集上测试,得到火焰漏检率如图 11 所示。

通过对比,添加 L-Fire 标签后,火焰漏检率明显下降,表明本文根据火焰特征分类建立新的 FireData 训练集可以有效减少漏检率;而不添加弱火焰标签,深度学习网络会把这类占比较小的火焰当作负样本,从而出现较大漏检率。在新的

表 3 算法性能对比

Table 3 Comparison of algorithm performance

Model	YOLOv3	Fast-RCNN	Faster-RCNN	R-FCN	LOF-FCN
Speed/(frame/s)	34	0.6	7	13	17
mAP/%	76.2	54.0	83.9	80.3	81.7

由图 12 和表 3 可知,Faster-RCNN 检测精度最高,因为 Faster-RCNN 对每幅图片使用多达 2000 个目标框确定目标位置,但大量的目标框使用也使 Faster-RCNN 检测速度较慢。YOLOv3 检测




图 11 火焰漏检率对比

Fig. 11 Comparison of fire missed detection rate

FireData 训练集上采用 LOF-FCN 方法训练模型,漏检率进一步下降,表明本文提出的方法可以有效提高火焰检测精度。

5.2 算法性能对比

在公开的图像数据集 VOC2007 上预训练 YOLOv3、Fast-RCNN、Faster-RCNN、R-FCN 以及本文提出的 LOF-FCN 方法,然后在添加标签的 FireData 训练集上微调,最后在 VisiData 测试集上测试火焰检测精度,以平均精度(mAP)作为评价标准,火焰检测精度对比如图 12 所示。




图 12 火焰检测精度对比

Fig. 12 Comparison of fire detection accuracy

现阶段火焰检测的研究工作,是火灾识别的重要前提,因此除了检测精度,检测速度也是重要检测指标。在 VisiData 测试集上,将本文方法分别与 YOLOv3、Fast-RCNN、Faster-RCNN 及 R-FCN 对比,得到表 3。

速度最快,是因为包含 YOLOv3 在内的单步检测方法将目标位置信息及分类信息融合在一个网络中计算,但相应的检测精度低于大部分双步检测方法。

本文提出的 LOF-FCN 方法检测精度略低于

Faster-RCNN,检测速度仅次于YOLOv3,综合考虑检测速度和检测精度,本文提出的LOF-FCN火焰检测方法检测效果明显,且检测精度和速度都得到了提高。

5.3 视频实验结果

验证视频取自VisiData测试集,视频来源于Bilkent大学的火焰视频库与互联网视频网站,且未在FireData训练集中出现。图13为验证视频,图13(a)、(b)为弱火焰检测,图13(c)、(d)为强火焰检测,图13(e)、(f)为干扰视频,无火焰。

实验在CPU为i7-4790 4 GHz, GPU为1070Ti,内存为16 G,操作系统为windows 7的环境下进行。网络训练20000步时已经达到很好的收敛效果,所以设计训练步骤为20000步;受计算机配置影响,设置一次训练处理12幅样本图片。

将LOF-FCN与其他方法在4个火焰视频以及2个非火焰视频中进行检测对比,得到表4、5数据。TP代表火焰检出率,FP代表漏检率,TN代表非火焰

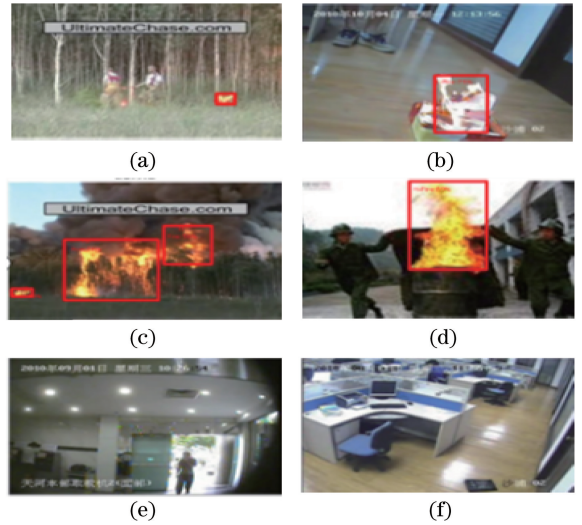


图13 实验视频。(a)视频1;(b)视频2;(c)视频3;(d)视频4;(e)视频5;(f)视频6

Fig. 13 Experimental video. (a) Video 1; (b) video 2; (c) video 3; (d) video 4; (e) video 5; (f) video 6

视频检出率, FN代表误检率,均值保留一位小数。

表4 火焰检测效果

Table 4 Detection results of flame

Video	Video frame	Fire frame	Method in Ref. [6]		Method in Ref. [8]		Method in Ref. [9]		Proposed method	
			TP / %	FP / %	TP / %	FP / %	TP / %	FP / %	TP / %	FP / %
1	170	156	96.2	3.8	97.6	2.4	98.6	1.4	99.2	0.8
2	234	257	94.5	5.5	93.2	6.8	92.7	7.3	95.4	4.6
3	200	182	99.3	0.7	99.8	0.2	100	0	100	0
4	124	93	99.7	0.3	100	0	100	0	99.0	1.0
Average	182.0	172.0	97.4	2.6	97.7	2.3	97.8	2.2	98.4	1.6

表5 非火焰检测效果

Table 5 Detection results of non-flame

Video	Video frame	Fire frame	Method in Ref. [6]		Method in Ref. [8]		Method in Ref. [9]		Proposed method	
			TN / %	FN / %	TN / %	FN / %	TN / %	FN / %	TN / %	FN / %
5	420	0	98.8	1.2	97.3	2.7	95.4	4.6	98.3	1.7
6	376	0	97.2	2.8	96.2	3.8	96.7	3.3	97.6	2.4
Average	398.0	0.0	98.0	2.0	96.8	3.2	96.1	3.9	98.0	2.0

文献[6]采用单步检测器方法,该方法检测平均精度低于文献[8]方法、文献[9]方法以及本文方法。文献[8]对火焰进行细分,使用Faster-RCNN方法,获得良好检测效果,但对小目标^[15]检测效果较差,如视频1所示,检测效果不如本文方法。文献[9]使用传统R-FCN,通过二次分类提高检测精度,虽然检测精度得到提高,但缺少弱火焰标记,对视频2检测效果不佳。

文献[8]中Faster-RCNN方法和文献[9]中R-FCN方法,都采用分类置信度作为非极大值抑制的排序依据,导致部分定位更精确的候选框被舍去。

而本文通过R-FCN网络对火焰信息进行卷积学习,构建深度卷积模型,同时通过引入可分离卷积、平移伸缩操作、精准池化和定位置信度加以改进,提升了火焰检测精度。

6 结 论

本文在R-FCN基础上引入定位置信度,解决了R-FCN方法在选择候选框时会错误删除更准确候选框的问题,同时通过可分离卷积提高检测速度,通过平移伸缩操作使得火焰图像更完整,通过精准池化操作减少取整误差,提升火焰检测效果。最后

添加弱火焰与强火焰标签,加强对弱火焰的训练,降低漏检率。综上实验结果可知,基于定位置信度和区域全卷积网络的火焰检测方法检测精度更高,检测速度达到了实时检测需要。

参 考 文 献

- [1] Esfahlani S S. Mixed reality and remote sensing application of unmanned aerial vehicle in fire and smoke detection[J]. Journal of Industrial Information Integration, 2019, 15:42-49.
- [2] Qureshi W S, Ekpanyapong M, Dailey M N, et al. QuickBlaze: early fire detection using a combined video processing approach [J]. Fire Technology, 2016, 52(5):1293-1317.
- [3] Frizzi S, Kaabi R, Bouchouicha M, et al. Convolutional neural network for video fire and smoke detection[C]//IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society. 23-26 Oct. 2016, Florence, Italy. New York: IEEE Press, 2016:877-882.
- [4] Hao G, Yang Y K, Yi Q. General target detection method based on improved SSD[C]//2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). 24-26 May 2019, Chongqing, China. New York: IEEE Press, 2019:1787-1791.
- [5] Lan W B, Dang J W, Wang Y P, et al. Pedestrian detection based on YOLO network model[C]//2018 IEEE International Conference on Mechatronics and Automation (ICMA). 5-8 Aug. 2018, Changchun, China. New York: IEEE Press, 2018:1547-1551.
- [6] Du C X, Yan Y Y, Liu Y A, et al. Video fire detection method based on YOLOv2 [J]. Computer Science, 2019, 46(6):301-304.
杜晨锡, 严云洋, 刘以安, 等. 基于 YOLOv2 的视频火焰检测方法[J]. 计算机科学, 2019, 46(6):301-304.
- [7] Wu S, Zhang L. Using popular object detection methods for real time forest fire detection[C]//2018 11th International Symposium on Computational Intelligence and Design (ISCID). IEEE, 2019.
- [8] Hui T, Halidan · Abudureyimu, Du H. Multi-type flame detection combined with Faster R-CNN [J]. Journal of Image and Graphics, 2019(1):73-83.
回天, 哈力旦·阿布都热依木, 杜哈. 结合 Faster R-CNN 的多类型火焰检测[J]. 中国图象图形学报, 2019(1):73-83.
- [9] Hong W, Li C F. Flame detection method based on regional fully convolutional networks with residual network [J]. Laser & Optoelectronics Progress, 2018, 55(4): 041011.
洪伟, 李朝锋. 基于区域全卷积网络结合残差网络的火焰检测方法[J]. 激光与光电子学进展, 2018, 55(4): 041011.
- [10] 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.
- [11] Jiang B R, Luo R X, Mao J Y, et al. Acquisition of localization confidence for accurate object detection[M]// Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 816-832.
- [12] Zhou R G, Cheng Y, Liu D Q. Quantum image scaling based on bilinear interpolation with arbitrary scaling ratio [J]. Quantum Information Processing, 2019, 18(9):1-19.
- [13] Ji X S, Wang H. Head detection method based on optimized deformable regional fully convolutional neural networks [J]. Laser & Optoelectronics Progress, 2019, 56(14):141009.
吉训生, 王昊. 基于优化可形变区域全卷积神经网络的人头检测方法[J]. 激光与光电子学进展, 2019, 56(14):141009.
- [14] Elizabeth M M. Self-regulatory organizations; NYSE Arca, Inc.; Order granting an extension to limited exemption from rule 612(c) of regulation NMS in connection with the exchange's retail liquidity program until september 30, 2019 [J]. Federal Register FIND, 2019, 84:192.
- [15] Chen Z, Ye X Y, Qian D W, et al. Small-scale pedestrian detection based on improved Faster R-CNN[J]. Computer Engineering, 2020, 46(9): 226-232, 241.
陈泽, 叶学义, 钱丁炜, 等. 基于改进的 Faster R-CNN 小尺度行人检测[J]. 计算机工程, 2020, 46(9): 226-232, 241.
- [16] Krittanayawach N, Vateekul P. Robust compression technique for YOLOv3 on real-time vehicle detection[C]//2019 11th International Conference on Information Technology and Electrical Engineering (ICITEE). 10-11 Oct. 2019, Pattaya, Thailand. New York: IEEE Press, 2019:1-6.