

基于 Fire-MCANet 的火焰检测模型

祝巧巧, 严云洋, 冷志超, 董可, 叶翔, 王盘龙

(淮阴工学院计算机与软件工程学院, 江苏 淮安 223003)

✉ 1546906478@qq.com; yunyang@hyit.edu.cn; 1067321462@qq.com;
1553789590@qq.com; 1528411799@qq.com; 905610658@qq.com



摘要:针对火焰检测参数量和计算量较大及准确度较低的问题,提出一种基于 Fire-MCANet (Fire-Max Convolution Activate Networks)的火焰检测模型。该模型首先构建一种 MCA(Max Convolution Activate)模块,使用大卷积核获取感受野,提高特征提取的能力;其次构建主干网络 MCANet Block,在提升感受野的同时,降低模型的参数量和计算量;最后引入 CA(Coordinate Attention)注意力机制获取火焰的位置信息。实验结果表明,基于 Fire-MCANet 的火焰模型的检测准确率达到 95.75%,计算量仅有 2.13 GMac;其网络模型的结构比 ConvNeXt 网络更加轻量化,检测效果也更好。

关键词:火焰检测;深度学习;CA 注意力机制;特征提取

中图分类号:TP391 **文献标志码:**A

Flame Detection Model Based on Fire-MCANet

ZHU Qiaoqiao, YAN Yunyang, LENG Zhichao, DONG Ke, YE Xiang, WANG Panlong

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

✉ 1546906478@qq.com; yunyang@hyit.edu.cn; 1067321462@qq.com;
1553789590@qq.com; 1528411799@qq.com; 905610658@qq.com

Abstract: Aiming at low accuracy of flame detection with large number of parameters and calculations, this paper proposes a flame detection model based on Fire-MCANet (Fire-Max Convolution Activate Networks). Firstly, a Max Convolution Activate (MCA) module is constructed to obtain the receptive field by using a large convolutional kernel to improve the ability of feature extraction. Secondly, the backbone network MCANet Block is constructed to improve the receptive field and reduce the number of parameters and calculations of the model. Finally, the CA (Coordinate Attention) attention mechanism is introduced to obtain the position information of the flame. The experimental results show that the detection accuracy of the flame detection model based on Fire-MCANet reaches 95.75%, and the computational amount is only 2.13 GMac. Its network model is lighter than the ConvNeXt network, and the detection effect is better.

Key words: flame detection; deep learning; CA attention mechanism; feature extraction

0 引言(Introduction)

火灾是一种常见的灾害,可能会造成巨大的财产损失和人员伤亡。在许多场景中,如化工厂、仓库和公共建筑等,火焰检测的重要性不言而喻。火焰检测技术旨在帮助人们及早发现

火灾,以便及时采取措施进行灭火和人员疏散,最大限度地降低火灾造成的人员伤亡和财产损失,保护人们的生命财产安全。目前,火焰检测的主流方法有两种,即基于传统机器学习的方法和基于深度学习的方法。基于传统机器学习的方法如

支持向量机(SVM)^[1]、决策树^[2]等,通过提取手动设计的特征检测火焰。基于深度学习的方法有卷积神经网络(CNN)^[3]、YOLO 系列^[4]等深度学习模型。卷积神经网络通过端到端的学习从图像或视频数据中学习火焰的特征表示,但其性能和计算复杂度较高。通常,火灾事故发生初期的火焰检测目标尺寸较小,使得模型很难准确地提取到火焰的特征,并且当前模型对火焰检测的准确率较低。

1 相关研究(Related research)

火焰是一种非刚性的物体,其形状和尺寸会随着燃烧条件的改变而不断变化,给火焰检测的研究带来了困难。马庆禄等^[5]提出了一种基于红外热成像的公路隧道火灾初期火焰检测方法,利用温度阈值获取疑似火焰区域;HOSSEINI^[6]等提出一种高效卷积神经网络架构 UFS-Net,用于检测视频帧中的火焰和烟雾,采用基于深度学习的火焰检测方法提取火焰特征,提升了发现刚出现火焰的速度,在保证速度的前提下,也拥有很好的识别能力。但是,上述改进模型不能很好地解决火焰在不同场景下的漏检、误检问题。本文针对这些问题提出一种基于 Fire-MCANet 的火焰检测模型,该模型能够提高火焰检测精度并降低模型计算的复杂度。

2 Fire-MCANet 火焰检测模型 (Fire-MCANet flame detection model)

2.1 ConvNeXt 网络

ConvNeXt^[7]是一种基于卷积神经网络的深度学习框架,常被用于图像分类和目标检测任务的网络结构,与其他经典的CNN(Convolutional Neural Networks)结构相比,具有更高的准确性和更少的参数量。ConvNeXt 的网络结构主要由以下几个部分组成:Input(输入层)、Convolution(卷积层)、Layer Norm(归一化层)、ConvNeXt Block(卷积连接块)、Downsample(下采样层)、Globe Avg Pooling(全局平均池化层)和 Linear(线性层)。输入层接收图像,并将其转化为特征图。归一化层对网络的每个神经元输出进行归一化,使得网络中的每一层的输出都具有相似分布。卷积连接块是 ConvNeXt 网络的基本模块。下采样层对特征图进行缩放。全局平均池化层用于对特征图进行降维,将其转换为一维向量,以便进行检测任务。线性层对特征向量进行处理,输出最终的检测结果。ConvNeXt 的网络结构如图 1 所示。

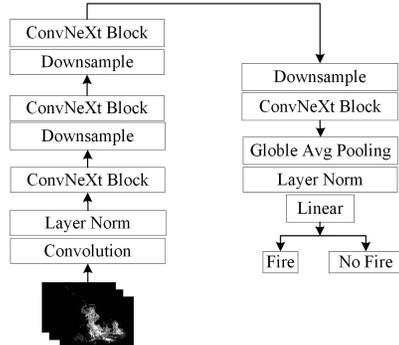


图 1 ConvNeXt 的网络结构

Fig. 1 Network structure of ConvNeXt

卷积连接块由 Depthwise Convolution(分组卷积)、归一化层、Gaussian Error Linear Units(GELU 激活函数)、卷积层、Layer Scale(缩放层)、Drop path(正则化)和 Concat(拼接)组成。卷积连接块首先将输入的特征图进行分组,其次对每个分组内的特征图进行卷积操作,提取不同组之间的特征关系。分组卷积之后,对每个分组内的特征图进行卷积核大小为 1×1 的卷积操作。先使用卷积核大小为 1×1 的卷积进行通道数的升维,再使用卷积核大小为 1×1 的卷积对特征图进行降维操作,在保证特征提取能力的同时,降低了计算复杂度。将得到的特征图与输入特征图进行残差连接^[8],得到最终的输出特征图。ConvNeXt Block 模块如图 2 所示,图 2 中的 k 代表卷积核大小; s 代表卷积核在图像窗口上每次平移的间隔,即步长。

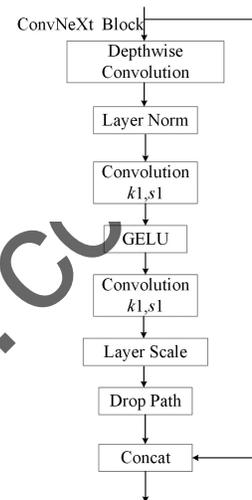


图 2 ConvNeXt Block 模块

Fig. 2 ConvNeXt Block module

归一化层和卷积层是下采样层的关键组件。归一化层用于下采样的初步处理,具有抗噪性和位置不变性的特点,能够对输入特征进行平移、旋转和缩放等变换,并保持不变性。卷积层是下采样的另一个关键组成部分,它通过卷积操作进一步处理特征图。卷积层可以通过不同的卷积核提取多个不同方向和尺度的特征,从而捕捉更丰富的语义信息。下采样在深度学习起着重要的作用,通过缩小输入特征图的尺寸,实现对特征的降维和提取更高层次的抽象特征。下采样层的主要目的是减少参数量和计算量,以及增强模型对整体结构的感知能力。下采样层的结构如图 3 所示。

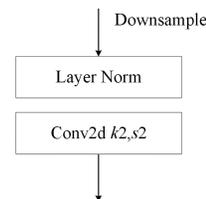


图 3 下采样层的结构

Fig. 3 Downsampling layer structure

2.2 MCA 模块

在火灾检测中,为了获取较好的特征提取能力,本文提出了一种 MCA 模块。该模块通过组合不同卷积的卷积核和激活函数,进行特征提取和非线性变换,以实现强大的模型表达

能力和性能。GELU 激活函数是一种高性能的神经网络激活函数,它的非线性变化是一种符合预期的随机正则变换方式,具有比传统的 ReLU(Rectified Linear Unit)^[9] 等函数更平滑和连续的性质,它可以引入更强的非线性能力,帮助模型更好地捕捉数据中的复杂模式和关系。通过在卷积核大小为 1×1 的卷积层后应用 GELU 激活函数,可以引入更多的非线性变换,增强模型的表达能力。使用具有较大的感受野的 11×11 的大卷积核^[10],能够捕捉更大范围的上下文信息,从而获取更丰富的火焰特征。左侧最下面的卷积核大小为 1×1 的卷积层被用于维度变换,即通过调整通道的数量改变特征的维度,帮助模型在特征空间中进行更好的整合和组合。在左侧最后一次卷积得到的结果与通过右侧卷积核大小为 1×1 的卷积层的结果相乘(Product)的步骤中,可以进一步整合特征信息,提供更丰富的特征表达。

MCA 模块使用大卷积核、GELU 激活函数和卷积核大小为 1×1 的卷积层的组合,旨在提高模型的表达能力、捕捉更大范围的上下文信息、引入更强的非线性能力,以及整合和调整特征维度。MCA 模块如图 4 所示。

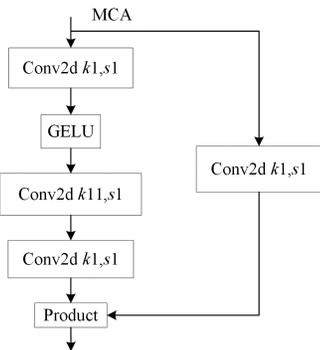


图 4 MCA 模块
Fig. 4 MCA module

2.3 MCANet Block 模块

本文参考 ConvNeXt 设计了主干网络 MCANet Block 结构。为了使模型获取更大的感受野,能够更好地进行特征提取,本文使用 MCA 模块代替 ConvNeXt Block 中用于升维的 1×1 卷积。MCANet Block 的网络结构由分组卷积、归一化层、MCA 模块、卷积层、GELU 激活函数、缩放层和正则化层拼接而成。MCANet Block 的分组卷积在不改变特征图大小的情况下,对输入特征进行空间信息的提取和压缩。MCA 模块可以提取更丰富的空间和通道特征信息,从而提高模型的表现能力,卷积层可以降低模型的参数量和计算量,从而提高模型的计算和内存效率。MCA 模块的使用提高了模型的鲁棒性和泛化能力。该模块进一步增强了网络的表达能力和泛化能力,同时能防止网络模型过拟合,提升模型的性能。MCANet Block 模块如图 5 所示。

2.4 加入 CA(Coordinate Attention)注意力机制

在火焰检测中,可应用注意力机制提高火焰检测模型对火焰区域的感知能力和关注能力,增强火焰区域的特征表示和检测准确性。Coordinate Attention^[11] 是一种基于坐标的注意力机制,用于在卷积神经网络中引入对位置信息的关注,它通过学习和应用输入数据的空间坐标信息,提供了一种有效的方式

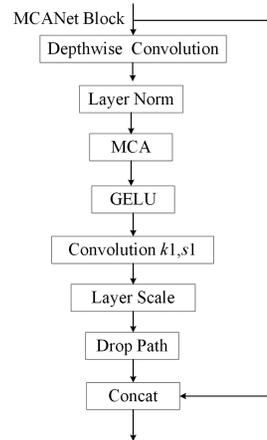


图 5 MCANet Block 模块
Fig. 5 MCANet Block module

用于捕捉位置相关的特征和模式。传统的注意力机制主要关注通道之间的特征,而 Coordinate Attention 注意力机制则专注于特征图中的空间位置,它通过将坐标信息与特征进行融合,使网络能够更好地理解和利用不同位置的特征差异。CA 注意力机制包括 Residual(残差边)、Global Avg Pooling(全局平均池化)、Convolution(卷积层)、Concat、BatchNorm(归一化层)、Non-linear(非线性层)、Sigmoid 激活函数和 Re-weight(重新加权)。

Coordinate Attention 的引入可以提升模型的性能,增强模型对位置信息的感知能力。Coordinate Attention 注意力机制模块如图 6 所示。

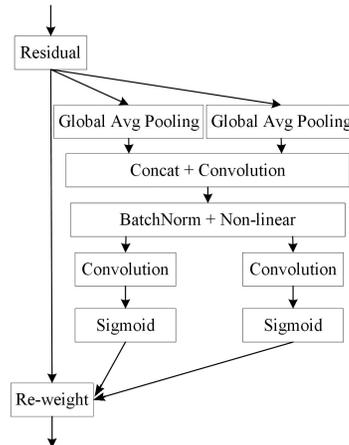


图 6 Coordinate Attention 注意力机制模块
Fig. 6 Coordinate Attention mechanism module

2.5 基于 Fire-MCANet 的火焰检测算法

火焰是一种非刚性物体且扩散速度极快,因此对其检测的精度和速度的要求较高。ConvNeXt 是一种基于卷积神经网络的深度学习框架,在检测目标较大且清晰时,检测效果较好,但是在一些特殊环境下,例如图片模糊、光照不足和目标重叠情况下,检测目标容易丢失而造成误检。在火焰检测中,不仅需要检测算法处理低清晰度图片,及时且快速地检测小目标图像,还要在训练时避免模型的训练时间过长及解决过拟合问题。

首先构建 MCA 模块替换 ConvNeXt Block 中卷积核大小为 1×1 的卷积块,其次采用主干网络 MCANet Block 和融入

Coordinate Attention 注意力机制,构成基于 Fire-MCANet 的火焰检测模型。Fire-MCANet 是一种基于卷积神经网络的火焰检测模型。Fire-MCANet 网络的整体架构遵循 ConvNeXt 的结构。该模型应用于火焰检测,不仅增强了火焰的特征提取能力,而且提高了目标检测的准确性和鲁棒性。Fire-MCANet 网络结构如图 7 所示。

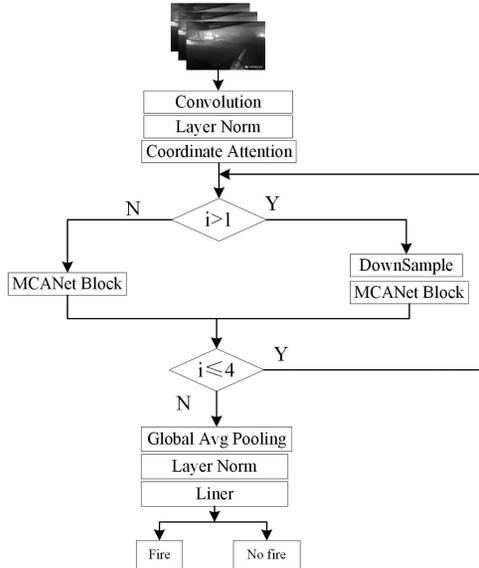


图 7 Fire-MCANet 网络结构

Fig. 7 Fire-MCANet network structure

3 实验结果及分析 (Experimental results and analysis)

3.1 实验环境

实验环境如表 1 所示。

表 1 实验环境

Tab.1 Experimental environment

类别	环境参数
操作系统	Windows 10 专业版
CPU	I7-9500 CPU
GPU	GeForce GTX GTX1650
RAM	16 GB
ROM	固态 1 TB
Python	Python3.7

本文使用的实验数据集由训练集和测试集两个部分组成。数据集来源于网络上收集的不同类型、不同场景下的图片和 PASCAL VOC 数据集。将收集的火焰图片和非火焰图片按照 7:3 的比例,分别创建训练集和验证集。图 8 为实验使用的数据样例,其中图 8(a)至图 8(c)为训练时使用的火焰图片;图 8(d)至图 8(f)为训练时使用的非火焰图片。



图 8 实验使用的数据样例

Fig. 8 Sample data used for the experiment

3.2 模型评价

本文将准确率(Accuracy, Acc)、精确率(Precision, Pre)、召回率(Recall, Rec)、参数量(Params)和计算量(Flops)作为模型性能的评价指标。

准确率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,计算方法如公式(1):

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

精确率是预测正样本数占所有预测正火的比例,计算方法如公式(2):

$$Pre = \frac{TP}{TP + FP} \quad (2)$$

召回率是所有预测正值中火焰正确预测的占比,计算方法如公式(3):

$$Rec = \frac{TP}{TP + FN} \quad (3)$$

其中:TP(True Positive)表示真阳性,FP(False Positive)表示假阳性。

模型的参数量和计算量是衡量一个网络复杂度的重要指标。在保持检测精度较高的前提下,模型参数量越小,对设备的要求也就越低;模型计算量越少,网络复杂度也越低。但在实验中,不同的计算代码结构可能会导致参数量和计算量的计算结果存在误差。因此,在对比实验中需要使用相同的计算代码结构计算参数量和计算量,确保结果的准确性。

3.3 实验对比

使用 3 组实验,分析了本文提出的改进方法对模型性能的影响,每组实验训练的参数一致。通过消融实验,能够验证和对对比改进模型后的性能,消融实验结果如表 2 所示。ConvNeXt_1 表示将 ConvNeXt Block 中用于升维的卷积层替换成 MCA 模块;ConvNeXt_2 表示引入了 Coordinate Attention 注意力机制;ConvNeXt_3 表示使用 MCA 模块和引入 Coordinate Attention 注意力构建的 MCANet 结构。

表 2 消融实验结果

Tab.2 Results of ablation experiments

算法	Acc/%	Pre/%	Rec/%	Flops/GMac
ConvNeXt	89.30	85.00	90.79	4.47
ConvNeXt_1	88.45	87.35	92.39	2.13
ConvNeXt_2	92.36	86.71	90.79	1.34
ConvNeXt_3	95.75	90.40	94.40	2.13

实验以 ConvNeXt 作为对照组,ConvNeXt_1 在将原 ConvNeXt Block 网络中用于升维的卷积层替换为 MCA 模块后,精确率提升了 2.35 百分点;ConvNeXt_2 通过引入 Coordinate Attention 注意力机制,使模型更加关注火焰的特征,模型的准确

率提升了 3.91 百分点,同时 Flops 也降低了 0.79 GMac; ConvNeXt_3 使用了 MCA 模块创建的 MCANet 结构,并引入 Coordinate Attention 注意力机制,不仅降低了模型的参数量和计算量,而且模型的特征提取能力也得到提升;在降低模型计算量的基础上,使模型更加关注火焰的特征提取,准确率也提升了 3.39 百分点。

为了进一步验证本文提出的基于 Fire-MCANet 的火焰检测模型的检测性能,将模型与 DenseNet^[12]、Swin Transformer^[13]、Faster R-CNN^[14]、ConvNeXt 等主流目标检测模型进行对比实验。采用指标 Accuracy、Precision 和 Recall 对每个模型进行评估,基于 Fire-MCANet 的火焰检测模型的计算量和参数量有了大幅度的下降,同时准确率相比其他网络模型有很大程度上提高,各模型的实验结果对比如表 3 所示。

表 3 各模型的实验结果对比

Tab.3 Comparison of experimental results for each model

模型	Acc/%	Pre/%	Rec/%	Params/M	Flops/GMac
DenseNet	78.99	64.77	85.53	6.96	2.88
Swin Transformer	90.73	66.91	85.90	26.2	4.43
Faster R-CNN	85.85	75.09	88.69	136.71	18.89
ConvNeXt	89.30	85.00	90.79	27.28	4.47
Fire-MCANet	95.75	90.40	94.40	12.46	2.13

实验表明,本文提出的基于 Fire-MCANet 的火焰检测模型,不仅可以大幅度降低模型的参数量和计算量,而且能够提升检测的准确率和精确率。DenseNet 模型的检测精确率相对较低。Swin Transformer 模型的检测准确率相对较高,但是检测精确率和召回率不能满足应用要求。Faster R-CNN 和 ConvNeXt 模型在火焰检测中性能表现相对较好,但是各方面的指标都有提升空间。Fire-MCANet 模型的参数量和计算量都大幅度降低,同时检测准确率高达 95.75%。

4 结论(Conclusion)

本文通过深度学习的方法,实现在提高准确率的同时,降低模型的参数量和计算量,提高模型的整体性能。对模型的改进主要是通过 MCA 模块中大卷积核获取更大的感受野;通过 MCANet Block 整体提升模型感受野,同时有效地降低了模型的参数量;使用 CA 注意力机制让模型关注到不同位置的信息,从而更好地捕捉到空间位置之间的关系和通道位置信息。未来,需要进一步优化模型,提高模型对小目标的检测性能,并进一步提高模型在复杂场景下的检测速度和精度。

参考文献(References)

[1] 刘滨,刘春,邵必飞,等. 基于增强支持向量机的电力隧道多状态全过程监控方法[J]. 计算技术与自动化,2023,42(4):41-46.

[2] 刘伟,谢林柏,彭力. 一种改进的增量型随机神经网络及应用[J]. 计算机与数字工程,2023,51(7):1681-1686.

[3] 马晓乐,王志海,胡绍海. 基于多形态学成分分析的图像融合[J]. 同济大学学报(自然科学版),2024,52(1):10-17.

[4] 梁金幸,赵鉴福,周亚同,等. 基于改进 YOLOv5s 网络模型的火灾图像识别方法[J]. 传感器与微系统,2024,43(1):157-161.

[5] 马庆禄,马恋,孔国英,等. 基于红外热成像的隧道火焰检测技术研究[J]. 火灾科学,2022,31(4):244-251.

[6] 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.

[7] LIU Z, MAO H Z, WU C Y, et al. A ConvNet for the 2020s[C]//IEEE. Proceedings of the IEEE: 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE,2022:11966-11976.

[8] 凡遵林,王浩,管乃洋,等. 单帧红外图像弱小目标检测研究综述[J]. 红外技术,2023,45(11):1133-1140.

[9] LI Y Z, YUAN Y. Convergence analysis of two-layer neural networks with ReLU activation[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM,2017:597-607.

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

[11] ZHANG Z L, JIN Q Y, WANG L N, et al. Video-based fire smoke detection using temporal-spatial saliency features[J]. Procedia computer science, 2022, 198(C):493-498.

[12] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//IEEE. Proceedings of the IEEE: 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017:2261-2269.

[13] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: hierarchical Vision Transformer using Shifted Windows[C]//IEEE. Proceedings of the IEEE: 2021 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2021:9992-10002.

[14] 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.

作者简介:

祝巧巧(1998-),女,硕士生。研究领域:数字图像处理,目标检测。

严云洋(1967-),男,博士,教授。研究领域:数字图像处理,模式识别。本文通信作者。

冷志超(1998-),男,硕士生。研究领域:数字图像处理,目标检测。

董可(1999-),男,硕士生。研究领域:数字图像处理,目标检测。

叶翔(1998-),男,硕士生。研究领域:数字图像处理,目标检测。

王盘龙(2000-),男,硕士生。研究领域:数字图像处理,目标检测。