

基于改进卷积神经网络模型的火灾检测方法

马杰, 何子龙, 叶煜婷, 刘琼, 毛肇辉, 谭平*

湖南工商大学智能工程与智能制造学院, 湖南 长沙 410000

DOI: 10.61369/TACS.2025130037

摘 要 : 为解决传统消防通信系统中烟雾报警器易受粉尘干扰、户外监测能力弱、缺乏直观图像数据等问题, 结合现有图像检测技术与卷积神经网络研究, 并考虑到移动设备资源有限的实际情况, 本文提出了一种基于深度学习的火灾检测方法, 通过改进传统的卷积神经网络实现对火灾图像特征的检测、识别。实验结果表明: 采用了改进的 MobileNet 模型实现了模型的轻量化; 添加改进的 ECA 注意力机制, 在能兼顾轻量化同时保障了准确率; 改进后的模型准确率达到 98.28%, 召回率达到 95.54%, F1 分数达到 96.62%, 可实现火灾的精准检测。

关 键 词 : 卷积神经网络; 轻量化部署; 图像检测; 火灾隐情

A Fire Detection Method Based on an Improved Convolutional Neural Network Model

Ma Jie, He Zilong, Ye Yuting, Liu Qiong, Mao Zhaohui, Tan Ping*

School of Intelligent Engineering and Intelligent Manufacturing, Hunan Technology and Business University, Changsha, Hunan 410000

Abstract : To address issues in traditional fire communication systems, such as smoke detectors being easily affected by dust, weak outdoor monitoring capability, and lack of intuitive image data, this study proposes a deep learning-based fire detection method by integrating existing image detection technologies and convolutional neural network research, while considering the limited resources of mobile devices. The method detects and recognizes fire image features by improving conventional convolutional neural networks. The experimental results show that the use of an improved MobileNet model enabled model lightweighting, and the addition of an enhanced ECA attention mechanism ensured both lightweight performance and high accuracy. The improved model achieved an accuracy of 98.28%, 95.54%, and an F1 score of 96.62%, respectively, demonstrating its capability for precise fire detection.

Keywords : convolutional neural networks; lightweight deployment; image detection; fire hazards

引言

传统的火灾检测常用烟雾报警器, 即烟雾报警器通过捕捉烟雾来判断是否发生火灾。发生火灾时, 烟雾比明火要早出现且很浓, 如果能精确地监测烟雾信号, 对灭火及预防火灾有很大帮助。烟雾报警器极易被粉尘等杂质干扰, 在空旷场所、空气流通的场所, 由于烟雾密度不够低, 会大大地影响它的检测精度^[1]。

近年来, 国内外为提高火灾准确检测做了许多研究工作, 如火灾早期对烟雾、温度等参数变化的检测^[2], 融合温度、CO 气体浓度与烟雾的多模态融合模型^[3]等。此外, 双波长光电式烟雾传感器也能显著提高准确率。但还是存在一些误报、漏报的现象, 一旦检测到火灾信息, 不能直观地给出图像信息, 不能确定火灾检测到的是错误报警。

图像检测因其成本低、监控范围广的特点, 有效地克服了烟雾报警器的不足。但火灾检测通常部署在摄像头、无人机等嵌入式设备或者边缘计算节点, 计算能力、存储能力有限, 无法进行大模型计算。因此, 本研究使用摄像头采集图像数据, 改进 MobileNetV3 模型, 轻量化部署于资源很少的移动设备, 提高火焰检测能力。

一、相关理论基础

1. 轻量化卷积神经网络研究

在计算机视觉领域, 卷积神经网络已经被应用在各个场景和

设备中, 为了保证精准度, 模型的深度越来越深, 模型的复杂度也越来越高, 但是庞大和复杂的网络模型很难应用在真实场景和移动终端。2017 年, MobileNet 系列被 Google 团队首次推出, 引领了轻量化模型的新潮流。

项目信息: 湖南省 2024 年度大学生创新创业训练项目 (S202410554125)。

* 通信作者: 谭平 (1981—), 男, 博士, 副教授, 研究方向为脑机接口, 模式识别。

深度可分离卷积是 MobileNetV1 的一大创新点。标准卷积的乘法计算量为：

$$D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F$$

其中， $D_K \cdot D_K$ 是卷积核大小， M 是输入特征图的通道数， N 是卷积核数量， $D_F \cdot D_F$ 是输出特征图的空间尺寸。而深度可分离卷积的乘法计算量为：

$$D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F$$

计算量对比为：

$$\frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_K^2}$$

当 3x3 卷积核时，总计算量将是标准卷积计算量的 $\frac{1}{8} \sim \frac{1}{9}$ ，这将大大减少计算量，同时参数量也随着这个比例减少。

然而，在实际应用中发现，MobileNetV1 里的 ReLU 会给通道数较低的特征图带来较大的信息损失，造成“死神经元”现象。因此 MobileNetV2 引入了线性瓶颈和逆残差结构，在 MobileNetV1 的基础上提高了网络的表达能力。标准残差结构的翻转，使 MobileNetV2 模型减少计算量的同时增强了模型性能。参数量也由 MobileNetV1 的 4.2M 降至 3.4M。

MobileNetV2 的逆残差结构的成功，使得 MobileNetV3 在沿用这一结构的基础上，加入了很多新技术，包括 SE(Squeeze-and-Excitation) 模块、NAS (Neural Architecture Search) 搜索方法等。另外，耗时层结构的重新设计，减少了 3000 万的乘法操作次数，但没有损失准确性。

MobileNetV4 引入了通用倒置瓶颈和 Mobile MQA(Multi-Query Attention) 注意力机制，能够实现不同硬件平台下的帕累托最优性能，但是加入的注意力机制需要一定的硬件算力，工程化部署案例和问题解决方案积累不如前面版本多。

2. 注意力机制研究

深度学习中，注意力机制是模拟人学习信息的一种选择性考虑过程，可以根据给定的输入数据的不同变化，变化注意力的权重，强调重要部分而忽略非重要部分。

注意力机制的核心思想是给定一组值 V ，以及与 V 相对应的键 K ，对于每一个查询 Q ，就 Q 计算与所有的键的相似度，再用 Softmax 函数计算出相应的权重向量；最后用该权重向量作为系数去加权求和值 V ，即可得到注意力输出：

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

其中， $\sqrt{d_k}$ 该缩放因子控制内积数值的量级，使权重具有单位方差，保证 Softmax 梯度的稳定性

通道注意力机制是自适应学习通道权重对有效特征进行改进的一种功能，能够为 MobileNet 等轻量化模型突破瓶颈提供关键支撑。

在 MobileNetV3 中，SE 注意力机制借助自动学习的方式，让另一个全新的神经网络来获取特征图中每个通道的重要程度，然后根据不同的重要程度对不同的特征赋予一个权重值，可以使某些特征通道被神经网络重点聚焦。但是，SENet 中的降维操作会

给通道注意力机制带来负面影响，同时捕获所有通道之间的依存关系也会浪费时间，而且没有必要。于是，ECANet 便应运而生。

ECANet 进行不同通道之间信息的交互时做一维卷积，用一个自适应函数改变卷积核的大小。因此，有更多通道的层的通道之间会更多地进行交互，自适应函数：

$$k = \left\lceil \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma_{odd}} \right\rceil$$

其中 K 是卷积核大小， C 是通道数， $\gamma=2$ ， $b=1$ ， $\lceil \cdot \rceil_{odd}$ 表示取最近的奇数。

由此可见，ECA 就是 SE 的基础性改进提取通道注意力，用一维卷积取代全连接，跨通道操作不去降维，让通道和权重直接对应，减少了参数量，加快了速度，性能、速度与 SE 几乎一样，但是减少了计算量和参数量，更适用于轻量化模型。

二、系统模型和关键技术

1. 整体网络架构设计

结合第一章针对 MobileNet 系列轻量化网络及注意力机制的研究，充分发挥各自的属性优势，同时互补其不足，改进 MobileNetV3 骨干网络，构建 MobileNetV3 骨干网络 +ECA 注意力机制，采用知识迁移的方法做到“高精度、轻量化”的平衡。

2. 改进型骨干网络设计

将以 MobileNetV3-Small 为骨干网络对火灾检测场景做三点改进：

(1) 输入层预处理：将输入图像定位为 $224 \times 224 \times 3$ ，标准化、归一化等进行预处理。

(2) 输出层适配：将 MobileNetV3 原 1000 类的分类头改为 2 分类，降低模型层级，大量减少模型参数量。

(3) 注意力机制改进：将注意力机制替换了 MobileNetV3 模型原有 SE 注意力机制，性能和效率降低，参数量和计算复杂度提升。

三、实验与分析

1. 数据集构建

计算机视觉数据集数量和类型决定模型的性能，同时也决定了模型的稳定性、鲁棒性和泛化能力。因此，模型的训练方法参考 Debajyoti Mukhopadhyay 等选取的数据集策略，选取了 4 个不同的来源：

(1) 由 Foggia 等人构建的数据集，包含 31 段覆盖不同实时场景的视频，其中前 14 段为含火焰视频，后 17 段为无火焰视频；

(2) FIRESENSE 火焰与烟雾探测视频数据库，涵盖 11 段火灾视频与 16 段非火灾视频，通过 Python 代码从中提取图像帧后，对所有帧进行了随机打乱处理；

(3) Jivtesh Sharma 构建的数据集，包含 484 张火灾与非火灾图像；

(4) Kaggle 平台的森林火灾图片数据集, 共计5000张火灾与非火灾图像。

所有数据集同时划分为训练集、验证集与测试集三个目录, 其划分规则为: 把总图像数量的 20% 作为测试集, 其余80% 中的20% 分配给验证集, 其余全部用于模型训练。为缓解模型过拟合问题, 来源1与来源2的数据集同时用于训练集、验证集和测试集, 而来源3与来源4的数据集仅作为测试集。

为消除数据分布差异对模型训练的影响, 本研究采用标准化和归一化方法对输入图像进行预处理。

2. 实验环境及参数设置

实验环境的搭建分为软件环境和硬件配置。包括操作系统 Windows 11、编程软件 PyCharm、编译器 Python 3.8.10、深度学习框架 PyTorch 2.4.1、CUDA 12.1、GPU NVIDIA GeForce RTX 3060。

在实验参数设置方面, 模型训练的 batch_size 设置为32、使用 AdamW 优化器初始学习率为0.0005, 权重衰减为0.005、学习率下降方式设置为线性预热加余弦退火, 采用 Focal Loss 损失函数作为损失函数以综合优化模型对分类样本的学习能力, Epoch 设置为30个轮次。

3. 评价指标

混淆矩阵是分类模型性能的重要指标, 模型对样本进行分类后, 用矩阵形式来表示模型对样本的分类结果, 便于理解模型对于不同类别的表现。基本数据包括:

(1) True Positive (TP): 模型将实际为发生火灾的样本正确预测为发生火灾。

(2) False Negative (FN): 模型将实际为发生火灾的样本错误预测为未发生火灾。

(3) False Positive (FP): 模型将实际为未发生火灾的样本错误预测为发生火灾。

(4) True Negative (TN): 模型将实际为未发生火灾的样本正确预测为未发生火灾。

利用这些数据, 能够量化模型在不同类别上的表现, 计算出准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、假阳性 (FPR)、假阴性 (FNR) 以及 F1 分数 (F1-score)。各指标计算公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall(TPR) = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

$$FNR = \frac{FN}{TP + FN}$$

$$F1 = \frac{2 \times (Precision \times Recall)}{Precision + Recall}$$

其中, F1分数的取值范围为 [0, 1], 越接近1表示模型越好, 因为这表示模型能兼顾到查准率和查全率的平衡。所以想要检验

二分类模型在精准率和召回率之间的平衡问题时, F1分数有着相当重要的作用。

而过大的假阴性意味着模型可能无法及时检测到火灾, 延误救援时机, 造成不可弥补的损失。因此, 在火灾检测任务中除了关注整体的准确率、精确率和召回率, 还要关注假阴性率, 使模型具有较低的漏报率^[4]。

综上所述, 最终在模型评估上选择准确率、召回率、F1分数和假阴性作为评价指标。

4. 模型改进参数以及实验结果对比

对构建的数据集做了4种模型的对比实验, 分别为4种主干网络 MobileNetV2、MobileNetV3-Small、MobileNetV3-Large 以及修改了 MobileNetV3的 NewMobileNet 模型, 对应表2和表3中的 Model1、Model2、Model3和 Model4。

首先, 在开发板上资源有限的情况下, 模型的参数就非常关键。于是将4个模型的参数对比见表1。

表1 模型参数对比

模块	参数量	参数大小 (MB)
Model 1	2,226,434	8.49
Model 2	1,519,906	5.80
Model 3	4,204,594	16.04
Model 4	517,866	1.98

其次, 对产生的数据预处理后, 再将模型进行30轮次训练, 最终实验评价指标结果如表2所示。

表2 评价指标对比

	Model 1	Model 2	Model 3	Model 4
准确率	0.9714	0.9762	0.9809	0.9828
召回率	0.9554	0.9368	0.9480	0.9554
F1分数	0.9449	0.9527	0.9623	0.9662
假阴性	0.0446	0.0632	0.0520	0.0446

5. 消融实验

为了分析改进后模型的提高效果, 本研究还做了消融实验, 结果如表3所示。

表3 模型改进对比

Model	参数量	准确率	召回率	F1分数
a	1,519,906	0.9380	0.9219	0.8841
b	1,519,906	0.9762	0.9368	0.9527
c	605,482	0.9838	0.9480	0.9677
d	517,866	0.9828	0.9554	0.9662

首先, 本文实验基于原始的 MobileNetV3-Small 作为基线模型 Model a, 参数大小为5.8MB, 准确率为93.8%, 召回率92.19%, F1分数为88.41%。在此基础上, 进行三点改进, 并逐步分析效果。

改进一: 输入层预处理。在原模型 a 的基础上加入标准化和归一化, 即 Model b, 模型 b 准确率上升了3.82%, 召回率上升了1.52%, F1分数上升了6.86%, 这步改进消除了数据分布差异对模

型训练的影响,提高了模型收敛能力。

改进二:输出层适配。通过对模型 b 降低层级,即 Model c,参数量降低 60%,准确率增加 0.76%。这种降低层级的方法,能够让模型复杂度更适合二分类,极大降低模型参数量,提高模型推理速度。

改进三:将 SE 注意力机制替换成 ECA 注意力机制,即 Model d,模型进一步改善,准确率降低 0.10%,F1 分数下降 0.15%,但参数量却降低 14%,召回率提高 0.74%。ECA 注意力机制能够避免降维带来的信息损失,提高了模型计算效率,尤其是在降低参数量的同时保证了召回率^[5]。

由此可见,本研究使用的模型改进方法能够有效减少参数

量,同时提高模型精度。

四、结论

本文提出 MobileNetV3 火灾检测方法从数据预处理、层级结构改进、注意力机制改进三点改进。

改进后 NewMobileNet 的火灾检测任务的准确率为 98.28%,相比于原 MobileNetV3-small 提高 4.48 个百分点;模型参数量降低 65.93%,在降低模型复杂度的基础上进一步改进性能,本文所提出的模型相比于其他同类模型可以在保持轻量化的前提下提高检测精准度。

参考文献

- [1] 朱弥雪,刘志强,张旭,等. 林火视频烟雾检测算法综述 [J]. 计算机工程与应用, 2022, 58(14): 16-26.
- [2] 潘明明,王白根,齐红涛,等. 面向电气设施火灾早期检测的多模态融合模型 [J]. 电子技术应用, 2025, 51(06): 10-15.
- [3] 杨寒雨,赵晓永,王磊. 数据归一化方法综述 [J]. 计算机工程与应用, 2023, 59(03): 13-22.
- [4] 于营,杨婷婷,杨博雄. 混淆矩阵分类性能评价及 Python 实现 [J]. 现代计算机, 2021, (20): 70-73+79.
- [5] 许嘉,唐嵘蓉,吕品,等. 基于学习迁移的稳定知识追踪模型 [J]. 华南师范大学学报(自然科学版), 2024, 56(04): 68-79.