

基于稠密卷积神经网络的烟雾识别方法

程广涛^{1*}, 巩家昌², 李 建¹

(1. 国家消防工程技术研究中心 研发部, 天津 300381; 2. 中国刑事警察学院 声像资料检测技术系, 沈阳 110854)

(* 通信作者电子邮箱 gt_cheng@163.com)

摘 要:针对传统烟雾检测方法中提取的图像特征鲁棒性较差的问题,提出了基于稠密卷积神经网络(DenseNet)的烟雾识别方法。首先,利用卷积操作和特征图融合构建稠密网络块,在卷积层之间设计稠密连接机制,以增强稠密网络块结构内的信息流通和特征重用;然后,将已构建的稠密网络块叠加成稠密卷积神经网络用于烟雾识别,节省计算资源的同时提升对烟雾图像特征的表达能力;最后,针对烟雾图像数据量较小的问题,采取数据增强技术进一步改善训练模型的识别能力。在公开烟雾数据集上对提出的方法进行实验验证,实验结果表明,所提方法的模型大小只有0.44 MB,在两个测试集上的准确率分别为96.20%和96.81%。

关键词:烟雾识别;稠密连接;卷积神经网络;深度学习;数据增强

中图分类号:TP391.41 **文献标志码:**A

Smoke recognition method based on dense convolutional neural network

CHENG Guangtao^{1*}, GONG Jiachang², LI Jian¹

(1. Department of Research and Development, National Center for Fire Engineering Technology, Tianjin 300381, China;

2. Department of Audio-Visual Information Detection Technology, Criminal Investigation Police University of China, Shenyang Liaoning 110854, China)

Abstract: To address the poor robustness of the extracted image features in traditional smoke detection methods, a smoke recognition method based on Dense convolution neural Network (DenseNet) was proposed. Firstly, the dense network blocks were constructed by applying convolution operation and feature map fusion, and the dense connection mechanism was designed between the convolution layers, so as to promote the information circulation and feature reuse in the dense network block structure. Secondly, the DenseNet was designed by stacking the designed dense network blocks for smoke recognition, saving the computing resources and enhancing the expression ability of smoke image features. Finally, aiming at the problem of small smoke image data size, data augmentation technology was adopted to further improve the recognition ability of the training model. Experiments were carried out on public smoke datasets. The experimental results illustrate that the proposed method achieves high accuracy of 96.20% and 96.81% on two test sets respectively with only 0.44 MB model size.

Key words: smoke recognition; dense connection; Convolutional Neural Network (CNN); deep learning; data augmentation

0 引言

烟雾检测已经成为早期火灾检测的重要技术。传统的烟雾检测设备中常见的是点型感烟探测器,它因为成本低和安装简便而被广泛应用。点型感烟探测器通过采样和分析火灾产生的烟雾颗粒浓度、气体温度和湿度等特征来触发报警,这样的工作原理使它应用在高大空间场所时很难发挥作用。近年来,随着城市内各种大型建筑的兴起,各种大型建筑和超大型建筑越来越多,急需一种新型的烟雾探测方法来弥补现有有点型感烟探测器存在的不足。在安全城市、安全社区、智慧消防等全新理念的提出下,各种视频监控系统已经在国内的大中城市里得到了大规模的普及,促使基于视频图像分析技术的烟雾检测算法被广泛研究^[1-2]。

现有的烟雾识别方法首先从烟雾图像中提取烟雾特征,然后将提取的特征经过支持向量机(Support Vector Machine,

SVM)等模式识别分类器进行最终识别,其中特征提取是烟雾识别方法取得高准确率的关键所在。Ferrai等^[3]利用小波变换构建一个隐马尔可夫树模型用于烟雾识别;Ye等^[4]利用自适应背景减法提取运动和颜色特征去检测图像序列中的烟雾和火焰;Yuan等^[5]利用金字塔局部二值化模式(Local Binary Pattern, LBP)特征和容积局部二值化模式(Volumn Local Binary Pattern, VLBP)特征的直方图序列进行视频烟雾检测;Yuan等^[6]利用高阶局部三元模式进行烟雾识别。然而现有的烟雾识别方法虽然都取得了很高的检测率,但同时也伴有较高的误报率,其原因在于传统的烟雾图像颜色、纹理、形状等特征鲁棒性较差,容易受光照条件、复杂的环境影响而变得异常不稳定,进而忽略图像中烟雾的本质特征。

深度卷积神经网络(Convolutional Neural Network, CNN)的出现很好地解决了特征提取的问题,它能够根据原始的图像数据自动学习鲁棒特征,既能学习边缘和纹理等低层特征,

收稿日期:2019-09-17;修回日期:2019-10-25;录用日期:2019-10-25。 基金项目:应急管理部天津消防研究所基金资助项目(2018SJ20)。

作者简介:程广涛(1983—),男,黑龙江大庆人,工程师,博士,主要研究方向:图像处理、模式识别、深度学习; 巩家昌(1983—),男,山东临沂人,讲师,博士,主要研究方向:图像处理、模式识别; 李建(1992—),女,河北沧州人,工程师,硕士,主要研究方向:数据挖掘、图像处理。

也可以学习高阶的抽象特征,如此丰富的特征表示对图像识别非常重要。目前,卷积神经网络已经被广泛研究和被应用到各个图像分析领域,包括图像分类^[7]、目标检测^[8-9]、人脸识别^[10]等。Yin 等^[11]首次将卷积神经网络应用到烟雾识别问题中,提出了 14 层的深度规范和卷积神经网络 (Deep Normalization and Convolutional Neural Network, DNCNN) 用来实现烟雾图像特征提取和分类;王文朋等^[12]针对烟雾数据量较少的问题,提出一种基于深度迁移学习的烟雾识别方法,将 ImageNet 数据集作为源数据,利用 16 层的 VGG (Visual Geometry Group) 模型^[13]进行同构数据下的特征迁移;Yuan 等^[14]提出了深度多尺度卷积神经网络 (Deep Multi-scale CNN, DMCNN) 进行烟雾识别,DMCNN 由一些基本卷积块堆积而成,每个卷积块包含一些并行的卷积核大小不同的卷积层,用于对烟雾图像的多尺度特征提取。

稠密卷积神经网络 (Dense Convolutional Neural Network, DenseNet)^[15]由一些稠密块堆积而成,在每个稠密块的卷积神经网络中,当前层的输入数据来自前面所有层的数据,因此 DenseNet 可以缓解梯度消失,增强特征流通和特征重利用,并减少深度模型参数。借鉴 DenseNet 的优势,本文构造了用于烟雾识别的稠密卷积神经网络 (DenseSmoke)。首先根据烟雾图像特征利用卷积运算和特征图融合构建稠密网络块,然后叠加稠密网络块,设计用于烟雾识别的深度稠密卷积神经网络。该网络提取的丰富图像特征可以更好地对烟雾图像进行描述,达到了更高的准确率和更低的误报率,并且模型参数量大约只有 0.44 MB,可以更好地节省运算资源。

1 稠密网络块

深度卷积网络中层与层之间的稠密连接可以改善数据的




图 3 DenseSmoke 的网络结构

Fig. 3 Network structure of DenseSmoke

卷积层 输入的图像数据首先经过一个卷积层,其中卷积核大小为 3×3 ,滑动步长为 1,扩充参数为 1,以保证卷积后特征图分辨率大小不变,特征图通道数设置为 24。

稠密网络块 整个 DenseSmoke 网络由 N 个稠密网络块叠加而成,每个稠密网络块都包含 3 次基本构件操作和 3 次特征图拼接融合操作。文中设置 $N = 4$,这样每个稠密网络块的特征图分辨率依次为 48×48 , 24×24 , 12×12 和 6×6 ,特征融合后的特征图通道数目依次为 60、66、69、70。

压缩层 为了缓解特征图通道信息冗余,在每个稠密块后连接压缩层进行特征通道数目压缩,利用 1×1 卷积操作减少特征图的数目。假定特征块包含 m 个特征图,压缩层处理

信息流通,本文构造了稠密网络块,其基本构件依次由下面结构组成:批规范化 (Batch Normalization, BN),修正线性单元 (Rectified Linear Unit, ReLU),卷积核为 1×1 、通道数为 D 的卷积运算,BN,ReLU,卷积核为 3×3 、通道数为 C 的卷积运算,如图 1 所示。每个经过基本构件处理后的特征图都与前面所有层的特征图作拼接融合,融合后的特征图作为下一个基本构件的输入,以此类推,共经过 M 次基本构件操作和 M 次特征图融合操作。这样稠密网络块的最终特征图信息来自于其前面所有层,促进了信息流通和特征重利用。稠密网络块的结构如图 2 所示,文中设置 $M = 3$, $D = 48$, $C = 12$, I 表示稠密网络块输入的特征图通道数目。




图 1 稠密网络块基本构件

Fig. 1 Basic components of dense network block




图 2 稠密网络块结构

Fig. 2 Structure of dense network block

2 稠密卷积神经网络

整个稠密卷积神经网络 DenseSmoke 由卷积层、稠密网络块、压缩层、池化层、全局池化层和分类输出层构成,网络的输入是大小为 48×48 的 RGB 烟雾图像,如图 3 所示。

后将特征图减少为 $\lfloor \theta m \rfloor$,其中压缩因子 $0 < \theta \leq 1$,文中设置 $\theta = 0.5$ 。经过压缩层处理后,稠密网络块的特征图通道数依次为 30、33、34,最后一个稠密网络块不进行压缩。

池化层 池化层一般被连接在卷积层后面以减少特征图的分辨率,进而减少模型参数数量以节省运算资源和缓解过拟合问题。常见的池化方法有最大池化和平均池化,它们分别在池化区域内取最大值和平均值。本文选择平均池化方法,池化区域大小为 2×2 ,滑动步长为 2,这样池化层将特征图的分辨率降低为原来的 $1/4$ 。

全局池化层 在最后的特征图和分类层之间设置全局池化层,首先全局池化层可以加强特征图和分类层直接的信息

通信,其次全局池化层属于无参操作而避免过拟合问题,最后对于图像数据的空间平移全局池化层具有很强的鲁棒性。对大小为 $6 \times 6 \times 70$ 的稠密块进行池化区域为 6×6 的平均池化操作,输出为 $1 \times 1 \times 70$ 的特征图。

分类输出层 $1 \times 1 \times 70$ 的特征图中神经元经过线性变换后再经过 Sigmoid 函数变换进行图像二分类任务:

$$\begin{cases} p(y = 1|\mathbf{x}) = \frac{1}{1 + e^{-(\mathbf{W}\mathbf{x} + b)}} \\ p(y = 0|\mathbf{x}) = \frac{e^{-(\mathbf{W}\mathbf{x} + b)}}{1 + e^{-(\mathbf{W}\mathbf{x} + b)}} \end{cases}$$

其中: \mathbf{x} 表示分类输出层输入, y 表示烟雾和非烟雾标签, \mathbf{W} 表示神经元之间连接的权重, b 表示神经元之间连接的偏置。

3 实验结果与分析

本文使用 Pytorch 深度学习框架去构建和训练 DenseSmoke 网络。所有的实验运行在 Windows10 操作系统,实验主机配置主频为 3.40 GHz 的 i7-3700 CPU 处理器,16 GB 的 RAM 和 Nvidia GTX 1080Ti GPU 显卡。

3.1 网络训练

表 1 显示了江西财经大学袁非牛教授研究组公开的 4 个数据集 (<http://staff.ustc.edu.cn/~yfn/vsd.html>),分别为 Set1、Set2、Set3 和 Set4。实验中使用 Set3 作为训练数据集,Set4 作为验证数据集,其他的两个数据集作为测试数据集。

表 1 烟雾图像数据集
Tab. 1 Smoke image datasets

数据集	烟雾图像数量	非烟雾图像数量	图像总数量	用途
Set1	552	831	1383	测试
Set2	688	817	1505	测试
Set3	2201	8511	10712	训练
Set4	2254	8363	10617	验证

对于烟雾识别二分类问题,选择交叉熵损失函数来作为 DenseSmoke 网络的训练目标函数:

$$H = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \ln(p(y_i)) + (1 - y_i) \cdot \ln(1 - p(y_i)) \quad (1)$$

其中: y_i 表示数据集提供的样本标签,非烟雾图像的标签为 0,烟雾图像的标签为 1; $p(y_i)$ 表示样本被预测为 y_i 的概率; N 表示训练样本的个数。

本文使用批量随机梯度下降算法 (Batch Stochastic Gradient Descent, Batch-SGD) 训练深度卷积神经网络的参数变量,批量大小设置为 96,动量参数为 0.9,训练过程利用权重下降来进行正则化,其中 L_2 惩罚乘子设置为 10^{-5} ,学习率设置为 10^{-2} ,整个训练过程循环遍历训练数据集 300 次,每经过 100 次时将学习率除以 10 进行更新,学习率共被除以 2 次。网络权重初始化采用 Kaiming 初始化方法。如图 4 所示,训练过程很快就能收敛,大约遍历 90 次训练数据库时,训练准确率已经达到 100%,对应的损失函数值也开始趋于稳定。

3.2 实验评估

本文使用检测率 (Detection Rate, DR)、误报率 (False Alarm Rate, FAR) 和准确率 (Accuracy Rate, AR) 作为烟雾识别方法的量化评价指标,公式如下:

$$DR = \frac{P_p}{Q_p} \times 100\% \quad (2)$$

$$FAR = \frac{N_p}{Q_n} \times 100\% \quad (3)$$

$$AR = \frac{P_p + N_n}{Q_n + Q_p} \times 100\% \quad (4)$$

其中: Q_p 和 Q_n 分别表示烟雾样本和非烟雾样本的数目, P_p 表示烟雾样本中被正确检测为烟雾的数目, N_p 表示非烟雾样本中被错分为烟雾类别的数目, N_n 表示非烟雾样本中被正确检测为非烟雾的数目。烟雾识别算法的目标是使得 AR 指标和 DR 指标更高,同时使得 FAR 指标更低。





图 4 DenseSmoke 训练过程

Fig. 4 Training process of DenseSmoke

根据上述实验设置,表 2 汇总了不同烟雾识别算法训练的模型在测试集 Set1 和 Set2 上的实验结果,表中加粗数字表示各个指标下的最优值。从实验结果可以看到,与 DNCNN 和 DMCNN 相比较,DenseSmoke 在 Set1 测试集上达到更高的 DR 和 AR,在 Set2 测试集上达到更高的 DR,AR 值稍微低于 DMCNN,但 DenseSmoke 的模型大小只有 0.44 MB,还不到 DMCNN 模型大小的一半。除此之外,DenseSmoke 的 FAR 值在 Set1 和 Set2 测试集上都略高于 DNCNN 和 DMCNN,后面应用数据增强技术 (DenseSmoke_A) 进一步降低 DenseSmoke 的 FAR 值。

表 2 烟雾识别算法实验结果

Tab. 2 Experimental results of smoke recognition algorithms

算法	Set1			Set2			模型大小/MB
	DR/%	AR/%	FAR/%	DR/%	AR/%	FAR/%	
DNCNN	95.28	97.83	0.48	96.36	98.08	0.48	20.00
DMCNN	95.47	97.68	0.48	96.65	98.33	0.24	1.00
DenseSmoke	96.20	97.90	0.96	96.66	98.21	0.49	0.44
DenseSmoke_A	96.20	98.26	0.36	96.81	98.60	0.24	0.44

3.3 消融实验

为了更好地解释 DenseSmoke 网络构建的合理性,本文进行如下的消融实验。

1) 为了验证卷积神经网络中层与层之间稠密连接的必要

性,本文移除稠密网络块中的特征图融合操作,这时稠密网络块如图5所示,其基本构件依次由下列组件构成:BN,ReLU,卷积核为 3×3 、通道数为 D 的卷积运算。其他设置和DenseSmoke相同,在每个稠密网络块后面仍然附有压缩层和池化层,将如上描述的网络标记为DenseSmoke_0。

如表3所示,去掉稠密连接的DenseSmoke_0的模型参数由0.45 MB增加到1.08 MB,而DR和AR指标都发生较大的下降,同时FAR指标更高,在Set1测试集上DR指标甚至下降了3.45个百分点,在Set2测试集上FAR指标甚至升高了1.46个百分点。实验结果说明了稠密连接在烟雾识别任务中的必要性。




图5 DenseSmoke_0的稠密网络块

Fig. 5 Dense network blocks of DenseSmoke_0

表3 DenseSmoke消融实验结果

Tab. 3 Ablation experimental results of DenseSmoke

算法	Set1			Set2			模型大小/MB
	DR/%	AR/%	FAR/%	DR/%	AR/%	FAR/%	
DenseSmoke	96.20	97.90	0.96	96.66	98.21	0.49	0.44
DenseSmoke_0	92.75	95.95	1.92	94.91	96.61	1.95	1.08
DenseSmoke_1	94.38	97.47	0.48	94.48	97.08	0.73	0.28
DenseSmoke_2	95.30	97.61	0.84	95.20	97.48	0.61	0.63
DenseSmoke_3	93.48	97.04	0.60	92.44	96.28	0.49	0.33
DenseSmoke_4	94.20	97.32	0.60	93.75	96.81	0.61	0.55

2) DenseSmoke网络中稠密网络块有 M 次基本构件操作和 M 次特征图拼接融合操作,然后整个网络由 N 个稠密块叠加而成,文中设置 $M=3, N=4$ 。为了验证这样设置可以得到最好的性能,本文分别对 M 和 N 的取值减少和增加,详细设置如表4所示。

如表4所示,与DenseSmoke相比,减小 M 或 N 的值,模型大小有所减少,DenseSmoke_1和DenseSmoke_3的模型大小分

别只有0.28 MB和0.33 MB,但在测试集Set1和Set2上的检测率DR都发生了较大幅度的下降,说明降低模型复杂程度导致训练模型对图像特征的表达力不足,进而使得训练模型的识别性能下降。增大 M 或 N 的值,DenseSmoke_2和DenseSmoke_4的模型分别增加到0.63 MB和0.55 MB,但是模型大小的增加并没有导致训练模型的识别性能提升。这个结果的一个可能解释是:深度卷积神经网络达到令人满意的性能需要大量的训练数据做支撑,而烟雾图像数据量较小,利用深度卷积神经网络训练容易导致过拟合问题,训练的模型泛化能力较差,因此随着模型参数的增加其识别能力反而下降。通过以上实验和分析,文中提出的DenseSmoke网络当设置 $M=3, N=4$ 时可以达到最好的性能。

表4 消融实验中参数 M 和 N 的设置

Tab. 4 Settings of parameter M and N in ablation experiment

识别方法	M	N	识别方法	M	N
DenseSmoke_1	2	4	DenseSmoke_3	3	3
DenseSmoke_2	4	4	DenseSmoke_4	3	5

3.4 数据增强

深度卷积神经网络达到优异的性能需要大量的图像数据集作为保证。烟雾图像识别任务中存在的一个问题是烟雾图像训练数据的不充分,作为训练集的Set3只包含10712张图片,这样训练的深度卷积神经网络模型泛化能力差,即训练的模型只对少量的训练数据产生过好的效果,而对验证集和测试集效果较差。数据增强技术可以有效地缓解上述问题,它基于现有的少量训练数据集通过几何变换等操作达到扩充训练图像数据集的目的。本文采用水平翻转、垂直翻转和中心旋转3种数据增强技术,其中中心旋转对原有图像分别按照 90° 、 180° 和 270° 进行旋转。SetA表示在Set3基础上增强原有训练集中烟雾样本和非烟雾样本。增强的训练数据集详情如表5所示。

表5 数据增强处理后的训练数据集

Tab. 5 Training datasets after data augmentation

数据集	烟雾图像数	非烟雾图像数	图像总数
Set3	2201	8511	10712
SetA	13206	51066	64272

图6展示了通过数据增强技术产生的图像示例。

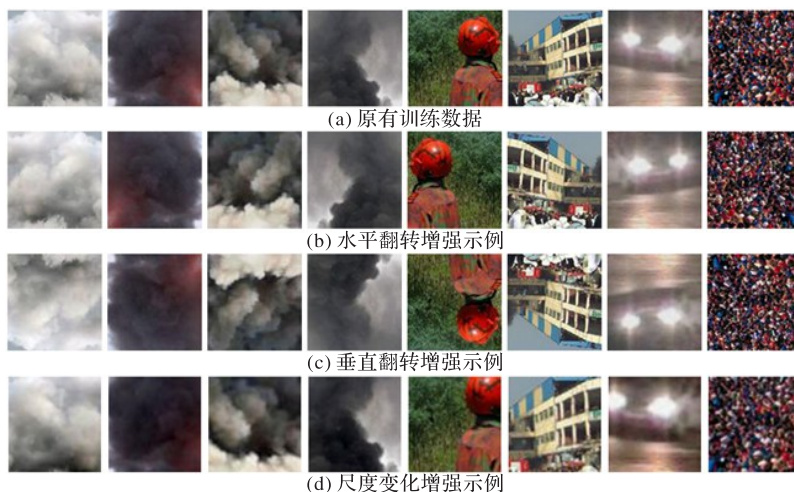


图6 数据增强处理产生的图像示例

Fig. 6 Image examples generated by data augmentation

表2中的DenseSmoke_A表示提出的DenseSmoke网络在增强后的数据集SetA上进行训练的实验结果。从实验数据中可以看到,通过数据增强技术对训练数据集进行扩充,DR和AR指标略有升高,同时FAR指标具有较大幅度的下降,在Set1数据集上FAR从0.96%降低到0.36%,在Set2数据集上FAR从0.49%降低到0.24%。DenseSmoke_A方法在两个测试集上分类错误的图像示例如图7所示。稀薄的烟雾图像和纹理不清楚的烟雾图像容易被错认为非烟雾,而树叶图像和模糊图像容易被识别为烟雾,成为误报的主要来源。




图7 DenseSmoke_A 错误分类示例

Fig. 7 Misclassification examples of DenseSmoke_A

4 结语

特征提取是烟雾图像识别的核心问题所在,而传统的特征提取技术容易受光照条件、复杂环境等因素干扰而具有较弱的鲁棒性。本文利用稠密卷积神经网络根据原始烟雾图像自动提取特征,由于卷积层之间的稠密连接,促进了深度网络结构中从低层特征到高层特征之间的信息流通,加强了特征重用。针对烟雾图像数据量较少问题,采取数据增强技术提高训练模型的识别能力。实验结果说明了提出的方法利用更少的模型参数达到更高的准确率和更低的误报率。

参考文献 (References)

- [1] 史劲亭,袁非牛,夏雪. 视频烟雾检测研究进展[J]. 中国图象图形学报, 2018, 23(3): 303-322. (SHI J T, YUAN F N, XIA X. Video smoke detection: a literature survey [J]. Journal of Image and Graphics, 2018, 23(3): 303-322.)
- [2] 许峰,于春雨,徐放. 视频烟雾火灾探测技术研究趋势[J]. 消防科学与技术, 2012, 31(11): 1185-1188. (XU F, YU C Y, XU F. Development of the video smoke detection technology research [J]. Fire Science and Technology, 2012, 31(11): 1185-1188.)
- [3] FERRARI R J, ZHANG H, KUBE C R. Real-time detection of steam in video images [J]. Pattern Recognition, 2007, 40(3): 1148-1159.
- [4] YE S, BAI Z, CHEN H, et al. An effective algorithm to detect both smoke and flame using color and wavelet analysis [J]. Pattern Recognition and Image Analysis, 2017, 27(1): 131-138.

- [5] YUAN F. Video-based smoke detection with histogram sequence of LBP and LBPV pyramids [J]. Fire Safety Journal, 2011, 46(3): 132-139.
- [6] YUAN F, SHI J, XIA X, et al. High-order local ternary patterns with locality preserving projection for smoke detection and image classification [J]. Information Sciences, 2016, 372: 225-240.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTO G E. ImageNet classification with deep convolutional neural networks [C]// Proceedings of the 25th International Conference on Neural Information Processing Systems. New York: Curran Associates, 2012: 1097-1105.
- [8] LIU L, OUYANG W, WANG X, et al. Deep learning for generic object detection: a survey [EB/OL]. [2019-08-22]. <https://arxiv.org/pdf/1809.02165.pdf>.
- [9] ZOU Z, SHI Z, GUO Y, et al. Object detection in 20 years: a survey [EB/OL]. [2019-05-16]. <https://arxiv.org/pdf/1905.05055.pdf>.
- [10] 方国康,李俊,王垚儒. 基于深度学习的ARM平台实时人脸识别[J]. 计算机应用, 2019, 39(8): 2217-2222. (FANG G K, LI J, WANG Y R. Real-time face recognition on ARM platform based on deep learning [J]. Journal of Computer Applications, 2019, 39(8): 2217-2222.)
- [11] YIN Z, WAN B, YUAN F, et al. A deep normalization and convolutional neural network for image smoke detection [J]. IEEE Access, 2017, 5: 18429-18438.
- [12] 王文朋,毛文涛,何建樑,等. 基于深度迁移学习的烟雾识别方法[J]. 计算机应用, 2017, 37(11): 3176-3181, 3193. (WANG W P, MAO W T, HE J L, et al. Smoke recognition based on deep transfer learning [J]. Journal of Computer Applications, 2017, 37(11): 3176-3181, 3193.)
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2018-03-22]. <https://arxiv.org/pdf/1409.1556.pdf>.
- [14] YUAN F, ZHANG L, WAN B, et al. Convolutional neural networks based on multi-scale additive merging layers for visual smoke recognition [J]. Machine Vision and Applications, 2019, 30(2): 345-358.
- [15] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [EB/OL]. [2016-08-24]. <https://arxiv.org/pdf/1608.06993.pdf>.

This work is partially supported by the Program of Tianjin Fire Research Institute of Ministry of Emergency Management (2018SJ20).

CHENG Guangtao, born in 1983, Ph. D., engineer. His research interests include image processing, pattern recognition, deep learning.

GONG Jiachang, born in 1983, Ph. D., lecturer. His research interests include image processing, pattern recognition.

LI Jian, born in 1992, M. S., engineer. Her research interests include data mining, image processing.