

中文引用格式:李海,熊升华,孙鹏.基于特征工程的S-FCN火灾图像检测方法[J].中国安全科学学报,2024,34(9):191-201.

英文引用格式:LI Hai, XIONG Shenghua, SUN Peng. S-FCN fire image detection method based on feature engineering [J]. China Safety Science Journal, 2024, 34(9): 191-201.

基于特征工程的S-FCN火灾图像检测方法*

李海¹讲师,熊升华¹副教授,孙鹏²教授

(1 中国民用航空飞行学院 民航安全工程学院,四川 德阳 618307;

2 中国刑事警察学院 公安信息技术与情报学院,辽宁 沈阳 110036)

中图分类号:X932

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2024.09.2063

资助项目:中央高校基本科研业务费专项资金资助(Q2023-051, J2023-062);四川省科技厅重点研发计划项目(2022YFG0213);民机火灾科学与安全工程四川省重点实验室自主资助项目(MZ2022JB03)。

【摘要】 针对复杂背景下火灾图像检测深度学习算法存在的计算复杂度高、检测实时性差等问题,提出一种基于特征工程的单隐层全连接网络(S-FCN)火灾图像检测方法。首先,从图像中提取多色彩空间颜色特征,并使用互信息量进行多色彩空间颜色特征降维;其次,简化深度学习模型的网络结构,将单隐层全连接网络作为其主干网络,其中,多色彩空间下的颜色特征能够更好地表征火灾烟雾与火焰,多色彩空间颜色特征降维能够有效降低输入特征的冗余度,单隐层全连接网络能够有效减少模型在传递过程中的参数数量;最后,将该方法在真实的复杂背景火灾图像数据集上进行试验评估。结果表明:所提方法取得的检测精度为93.83%,取得的检测实时性帧率为10 869帧/s,能够实现复杂场景下高精度、高速度的火灾图像检测。

【关键词】 特征工程; 单隐层全连接网络(S-FCN); 火灾图像; 检测方法; 色彩空间; 特征降维

S-FCN fire image detection method based on feature engineering

LI Hai¹, XIONG Shenghua¹, SUN Peng²

(1 College of Civil Aviation Safety Engineering, Civil Aviation Flight University of China, Guanghan Sichuan 618307, China; 2 School of Public Security Information Technology, Criminal Investigation Police University of China, Shenyang Liaoning 110036, China)

Abstract: The S-FCN fire image detection method based on feature engineering was proposed to address the issues of high computational complexity and poor real-time performance of deep learning algorithms for fire image detection in complex backgrounds. Firstly, this method extracted color features from images in multiple color spaces and reduced the dimensionality of these features using mutual information. Secondly, the network structure of the deep learning model was simplified by using a single hidden layer of a fully connected network as its backbone. The color features in multiple color spaces can better represent fire smoke and flames, and reducing the dimensionality of color features in multiple color spaces effectively reduces the redundancy of input features. The single hidden layer fully connected network can significantly reduce the number of parameters during the model propagation process. Finally, this method was evaluated on a real and complex background fire image dataset. The experimental results show that the detection

accuracy achieved by this method is 93.83%, and the real-time frame rate is 10 869 f/s. This method achieves high accuracy and high-speed fire image detection in complex scenes.

Keywords: feature engineering; single hidden layer fully connected network(S-FCN); fire image; detection method; color space; feature dimensionality reduction

0 引言

图像型火灾探测器作为火灾事故预防领域的研究热点之一,已广泛应用于森林、工矿、交通工具等场合的火灾探测过程中。近年来,随着机器视觉技术的迅猛发展,众多机器学习算法也已广泛应用于各种场景的火灾检测中。虽然这些方法在各种特定场景下取得了较高的检测精度,但在解决复杂背景下火灾图像检测问题时还存在数据平衡性差、计算复杂度高、检测实时性低等问题。因此,非常有必要研究一种兼具高精度与高实时性地检测复杂背景下火灾图像的方法,这对于防范复杂背景下火灾事故发生、保护公众生命和财产安全具有很现实的意义。

学者们对火灾图像检测技术的研究可分为2方面,一方面是基于特征工程的传统机器学习方法,另一方面是基于机器视觉的端到端深度学习方法。基于特征工程的传统机器学习方法主要难点在特征提取与选择上,在学习上主要基于决策树(Decision Tree, DT)、支持向量机(Support Vector Machine, SVM)、多层感知机(Multilayer Perceptrons, MLP)等经典传统学习方法,其优势在于检测实时性高,模型训练时间短,缺点在于特征工程阶段难以获取高效表征目标的特征。基于机器视觉的端到端深度学习方法的主要难点在于数据集的构建、网络结构的设计,优点在于可获得较高的检测精度,缺点在于训练时间长,检测实时性差,难以有效嵌入硬件平台^[1-2]。针对复杂背景图像中火灾区域的火焰检测问题,杨其睿^[3]提出一种改进的DenseNet深度神经网络结构。针对图像型火灾探测器检测过程中同时检测烟雾和火焰问题,YANG Yi等^[4]提出一种基于YOLOv3的图像型火灾探测算法;VENANCIO等^[5]提出一种适用于低功耗、资源受限设备的深度卷积神经网络模型;MAJID等^[6]提出一种融合注意力机制与EfficientNetB0的迁移学习架构。针对早期森林火灾探测的自动化监测系统,KHAN等^[7]提出一种基于VGG19的迁移学习方法;DOGAN等^[8]提出一种使用ResNet网络集成学习进行构建八特征向量的方法。针对室内烟雾与火焰探测系统,PINCOTT等^[9]提出一种Faster R-CNN Inception V2

模型;MUKHIDDINOV等^[10]提出一种改进的YOLOv4模型。针对早期火灾实时探测,DILSHAD等^[11]提出一种改进的VGG16网络模型。针对传统探测器容易受到外部环境的损坏或干扰等问题,AN Qing等^[12]提出一种使用视频序列的动态卷积YOLOv5火灾检测方法;AHN等^[13]提出一种基于视觉的早期火灾探测模型;HUANG Lida等^[14]提出一种使用小波提取光谱特征的方法。针对现有火灾探测模型中精度低、计算复杂度高等问题,KHAN等^[15]提出一种Stacked Encoded EfficientNet模型;HOSNI等^[16]提出一种基于Time-Efficient的火灾探测卷积神经迁移学习网络模型;LI Yuming等^[17]提出一种基于轻量级网络MobileNetV3的火灾探测模型。为了更好地实现对火灾位置、误报和模型大小之间的权衡,ZHANG Rong等^[18]提出一种基于深度学习的无锚架构火灾检测方法。

通过对当前研究的梳理,不难发现,很少有学者融合基于特征工程的传统机器学习方法与基于机器视觉的深度学习方法,各取所长,进行火灾图像的检测研究。为提高复杂背景下火灾图像检测的精度和实时性,笔者拟融合基于特征工程的传统机器学习方法与基于机器视觉的深度学习方法,提出一种基于特征工程的单隐层全连接网络(Single Hidden Layer Fully Connected Network, S-FCN)火灾图像检测方法。

1 基于特征工程的S-FCN网络火灾图像检测方法

1.1 多色彩空间下颜色特征降维

1.1.1 多色彩空间下颜色特征提取

多色彩空间下颜色特征是指每个样本中都可以提取到包含多个色彩空间颜色信息的特征。由于该特征能够提供更全面的信息,进而能够有效提升模型的精度性能。然而,随着色彩空间类型增加,其颜色特征数量也随之增加,这将导致模型复杂度和计算成本的提高。文中选用常用的Lab、红绿蓝三原色(Red, Green, Blue, RGB)、色彩-饱和度-亮度(Hue, Saturation, Value, HSV)这3种色彩空间进行

颜色特征提取。其中,RGB 色彩空间下的颜色特征计算过程如下式,HSV、Lab 色彩模式下的颜色特征可同理得出。

$$d_r = \sum_{i=1}^M \sum_{j=1}^N r/MN \quad (1)$$

$$d_g = \sum_{i=1}^M \sum_{j=1}^N g/MN \quad (2)$$

$$d_b = \sum_{i=1}^M \sum_{j=1}^N b/MN \quad (3)$$

$$m_r = \left[\sum_{i=1}^M \sum_{j=1}^N (r - d_r)^2 \right] / (MN) \quad (4)$$

$$m_g = \left[\sum_{i=1}^M \sum_{j=1}^N (g - d_g)^2 \right] / (MN) \quad (5)$$

$$m_b = \left[\sum_{i=1}^M \sum_{j=1}^N (b - d_b)^2 \right] / (MN) \quad (6)$$

$$k_r = \frac{d_r}{m_r}; k_g = \frac{d_g}{m_g}; k_b = \frac{d_b}{m_b} \quad (7)$$

$$D = \left[k_r - \frac{k_r + k_g + k_b}{3} \right]^2 + \left[k_g - \frac{k_r + k_g + k_b}{3} \right]^2 + \left[k_b - \frac{k_r + k_g + k_b}{3} \right]^2 \quad (8)$$

式中: r 、 g 、 b 分别为每个图像像素的红、绿、蓝 3 个分量值; d_r 、 d_g 、 d_b 为 RGB 图像各个分量信息的平均值; M 、 N 为图像的像素维数; m_r 、 m_g 、 m_b 为 RGB 图像各个分量信息偏色平均值; k_r 、 k_g 、 k_b 为 3 个分量偏色因子; D 为偏色因子方差。

1.1.2 多色彩空间下颜色特征贡献度检测

密度曲线图可表征不同特征对于常规图像和火灾图像数据分类的贡献度大小。当同一特征密度曲线图中 2 类数据的密度曲线差异较大时,表明此特征对于火灾图像与常规图像分类的贡献度较大;反之,当同一特征密度曲线图中 2 类数据的密度曲线差异较小时,表明此特征对于火灾图像与常规图像的分类贡献度较小。图 1 为多色彩空间下不同颜色特征对于火灾图像与常规图像分类的贡献度密度曲线图。其中, X_{11} 为 Lab 色彩空间下 a 通道颜色特征, X_{12} 为 Lab 色彩空间下 b 通道颜色特征, X_{13} 为 Lab 色彩空间下 a、b 通道颜色特征方差值特征, X_{21} 为 RGB 色彩空间下红色通道颜色特征值, X_{22} 为 RGB 色彩空间下绿色通道颜色特征值, X_{23} 为 RGB 色彩空间下蓝色通道颜色特征值, X_{24} 为 RGB 色彩空间下三通道颜色特征方差, X_{31} 为 HSV 色彩空间

下色调颜色特征方差, X_{32} 为 HSV 色彩空间下饱和度通道颜色特征, X_{33} 为 HSV 色彩空间下明度调通道颜色特征, X_{34} 为 HSV 色彩空间下三通道颜色特征方差值特征。

由图 1 可知:①与 3 种色彩空间下其他颜色特征相比,HSV 色彩空间下三通道颜色特征方差特征(X_{34})对于 2 类数据的密度分布曲线在低阶和高阶数据范围趋势基本一致,表明该特征对于火灾图像与常规图像的分类贡献度较小。②与 3 种色彩空间下其他颜色特征相比,RGB 色彩空间下三通道颜色特征方差(X_{24})特征对于 2 类数据的密度分布曲线在低阶和中高阶数据范围趋势基本重叠,表明该特征对于火灾图像与常规图像的分类贡献度较小。③与 3 种色彩空间下其他颜色特征相比,RGB 色彩空间下绿色通道颜色特征值(X_{22})特征对于 2 类数据的密度分布曲线在整个范围内分布趋势差异均较大,表明该特征对于火灾图像与常规图像的分类贡献度较高。④与 3 种色彩空间下其他颜色特征相比,HSV 色彩空间下饱和度通道颜色特征(X_{32})对于 2 类数据的密度分布曲线在整个范围内分布趋势差异均较大,表明该特征对于火灾图像与常规图像的分类贡献度较高。上述密度曲线分布规律有效反映出多色彩空间下不同颜色特征对于火灾图像与常规图像的分类贡献度差异较大,因此非常有必要对多色彩空间下不同颜色特征进行降维。

1.1.3 基于互信息量的多色彩空间颜色特征降维

在机器学习过程中,输入层特征强度是模型性能的关键保障,输入层特征数量大小严重影响着模型的计算复杂度。因此,对于输入特征进行降维,将会极大地降低模型的计算复杂度以及检测时间成本。颜色特征互信息量^[19-20]是指一个颜色特征中包含的关于另外一个颜色特征的信息量,表征 2 个颜色特征间的相关性,对于多色彩空间下的颜色特征而言,任意 2 个颜色特征 X 和 Y 的互信息量 $I(X, Y)$ 计算过程如下:

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \lg \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right) \quad (9)$$

式中: $p(x, y)$ 为待检图像中特定色彩空间下任意两颜色特征 X 和 Y 的联合分布列; $p_1(x)$ 、 $p_2(y)$ 为其边缘分布列。

图 2 为基于互信息量的多色彩空间下颜色特征对火灾图像与常规图像分类的具体贡献度分布。基于互信息量的颜色特征火灾图像检测贡献度得分排序能够有效量化各颜色特征对于图像检测类型的贡

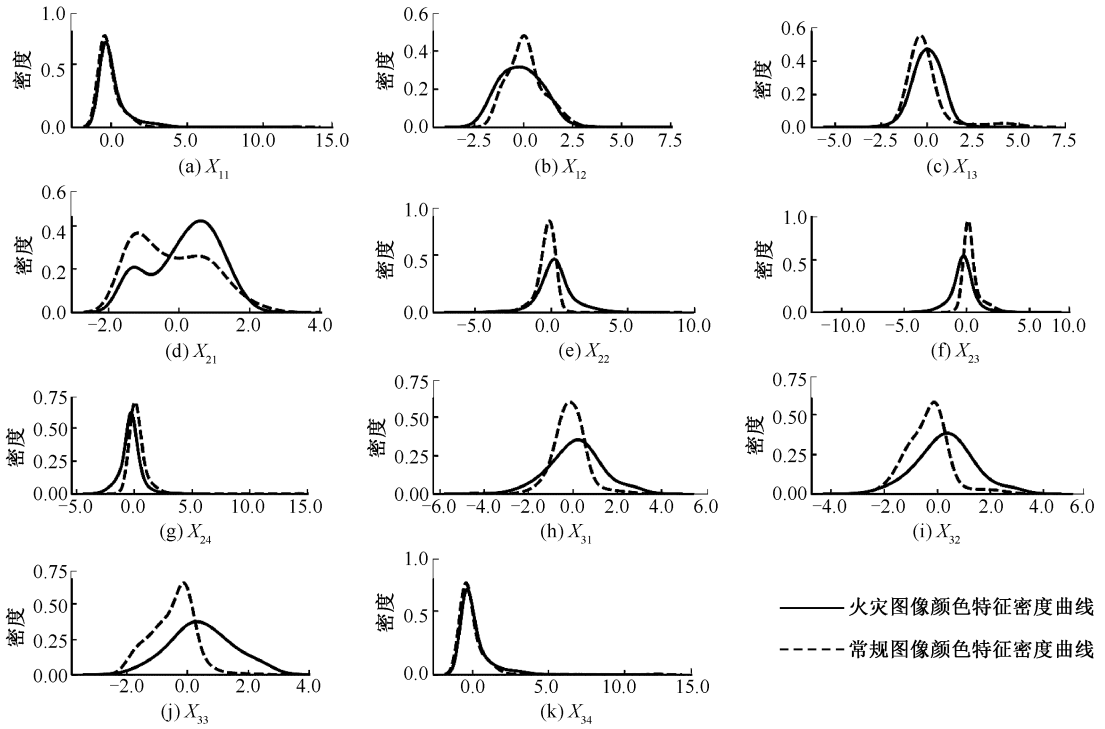


图 1 多色彩空间下不同颜色特征的密度曲线分布

Fig. 1 Density curve distribution of different color features in a multicolor space

献度大小。由图 2 可知:①在 Lab 色彩空间下,b 通道颜色特征(X_{12})对于火灾图像与常规图像分类贡献度明显高于 a 通道颜色特征(X_{11})。②在 RGB 色彩空间下,对于火灾图像与常规图像分类贡献度最高的是绿色通道颜色特征(X_{22}),蓝色通道颜色特征(X_{23})的分类贡献度较高,红通道颜色特征(X_{21})的分类贡献度最低。③在 HSV 色彩空间下,饱和度通道颜色特征(X_{32})对于火灾图像与常规图像的分类贡献度最高,色调通道颜色特征(X_{31})对于火灾图像与常规图像分类贡献度较高,明度调通道颜色特征(X_{33})的分类贡献度最低。④从 3 种色彩空间各通道颜色特征分布的方差值来看,RGB 色彩空间下红(R)、绿(G)、蓝(B)三通道颜色特征方差值特征(X_{24})对于火灾图像与常规图像分类的贡献度最高,HSV 色彩空间下色调(H)、饱和度(S)、明度(V)三通道颜色特征方差值特征(X_{34})的分类贡献度较高,Lab 色彩空间下 a、b 通道颜色特征方差值特征(X_{13})的分类贡献度最低。⑤从整体来看,RGB 色彩空间下的颜色特征对于火灾图像与常规图像的分类贡献度最高,HSV 色彩空间下的颜色特征的分类贡献度次之,Lab 色彩空间下的颜色特征的分类贡献度最低。

1.2 160-S-FCN 网络

机器学习中将神经网络按照隐层数量大小分为




图 2 不同颜色特征对火灾图像检测贡献度大小分布

Fig. 2 Distribution map of the contribution of different color features to fire image detection

单层和多层神经网络,其中单层神经网络是指只有一个隐层结构的神经网络,而多层神经网络是指包含 2 个及以上隐层结构的神经网络。全连接神经网络(Fully Connected Neural Network, FCN)是前馈神经网络的一种,由输入层、隐藏层和输出层组成,并且每个隐藏层中可以有多个神经元。S-FCN 是指隐藏层仅有 1 层的神经网络,其隐藏层神经元与输出层之间全部连接。图 3 为笔者设计的 160-S-FCN 网络结构,其中输入层 9 个,隐藏层 160 个,输出层 2 个。

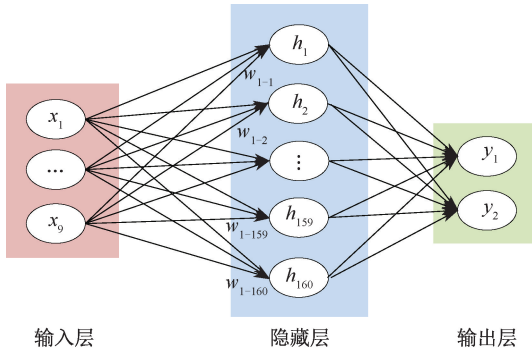


图 3 160-S-FCN 网络结构

Fig. 3 160-S-FCN network architecture

1.3 文中方法

1.3.1 方法流程

图 4 为基于特征工程的 S-FCN 网络火灾图像检测方法流程。该方法主要包括 5 部分,即图像数据预处理、颜色特征提取、特征降维、160-S-FCN 神经网络、分类预测结果输出。其中,图像数据预处理主要包括图像的 RGB、Lab、HSV 色彩空间转换,多色彩空间下不同颜色特征提取主要包含在 3 种色彩空间下分别提取颜色特征,多色彩空间下不同颜色特征降维主要指在 3 种色彩空间下基于互信息量大小进行特征的有效降维,160-S-FCN 神经网络是指针对复杂背

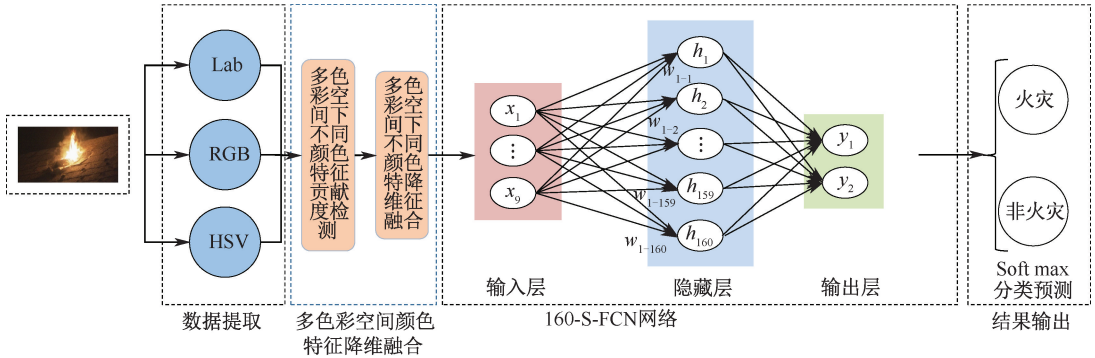


图 4 基于特征工程的 S-FCN 网络火灾图像检测方法流程

Fig. 4 Process of S-FCN network fire image detection method based on feature engineering

景下火灾图像检测所设计的具有 160 个神经元的单隐层全连接网络,该网络结构参数节点较少,有效降低了模型的计算复杂度,进而提高了实时检测速度。

1.3.2 模型结构与参数配置

文中设计的 160-S-FCN 网络结构具体配置见表 1。

表 1 160-S-FCN 网络结构配置

Table 1 Configuration of 160-S-FCN network structure

网络层	神经元个数	参数量
Dense_1 (输入层)	9	1 600
Batch_Normalization_1 (批标准化层)	9	18
Dropout_1 (正则化层)	9	0
Dense_2 (隐藏层)	160	1 600
Batch_Normalization_2 (批标准化层)	160	320
Dropout_2 (正则化层)	160	0
输出层	2	322

该模型的激活函数、损失函数、优化器、评价指标等具体信息如下。

1) 激活函数。隐藏层激活函数选择 ReLU, 输出层选择 Sigmoid 激活函数进行图像分类预测, 此时可将火灾图像检测问题转化为一个二分类问题。二分类预测使用的激活函数如下:

① ReLU 函数:

$$h(x) = \max\{0, x\} \quad (10)$$

式中 x 为输入值。

② Sigmoid 函数:

$$h(x) = \frac{1}{1 + \exp(-x)} \quad (11)$$

2) 损失函数。二元分类对数损失函数是一种用于衡量分类模型的损失函数,其常用于二元分类问题,具体计算过程如下:

$$\lg L = - \frac{1}{n} \sum_{i=1}^n ((y_i \times \lg(P_i) \times \delta) + (1 - y_i) \times \lg(1 - P_i)) \quad (12)$$

式中: n 为测试集样本数量; y_i 为测试集中第 i 个样本的真实标签; P_i 为第 i 个样本的预估转化率; δ 为惩罚系数。

3) 优化器。Adam(Adaptive Momentum)算法是一种自适应动量的随机优化算法,可以看作是动量法和 RMSprop 算法的结合,不但使用动量作为参数更新的方向,而且可以自适应调整学习率,具体计算过程如下:

$$M_i = \beta_1 M_{i-1} + (1 - \beta_1) g_i \quad (13)$$

$$G_t = \beta_2 G_{t-1} + (1 - \beta_2) g_t^2 \quad (14)$$

式中: M_t 为权重的衰减值; G_t 为目前为止 g_t 各个分量的平方的固定值; β_1 和 β_2 分别为 2 个移动平均的衰减率, 通常取值为 $\beta_1 = 0.9$ 和 $\beta_2 = 0.99$; g_t 为参数梯度。

假设 $M_0 = 0, G_0 = 0$, 那么在迭代初期 M_t 和 G_t 的值会比真实的均值和方差要小。特别是当 β_1 和 β_2 都接近 1 时, 偏差会很大。因此, 需要对偏差进行修正, 具体修正过程如下:

$$M_t = \frac{M_t}{1 - \beta_1^t} \quad (15)$$

$$G_t = \frac{G_t}{1 - \beta_2^t} \quad (16)$$

Adam 算法的参数更新差值如下式, 其中, 学习率 α 通常设为 0.001, 并且可以进行衰减, 如 $\alpha_t = \alpha_0 / \sqrt{t}$ 。

$$\Delta \theta_t = - \frac{\alpha}{\sqrt{G_t} + \varepsilon} \quad (17)$$

式中: ε 为平滑项; t 为时间。

4) 评价指标。

① 准确率:

$$A_{cc} = \frac{\sum_{i \in F} F(Y_i = \hat{Y}_i)}{|S| \times |S| - 1} \quad (18)$$

式中: Y_i, \hat{Y}_i 分别为待检图像真实类型与预测类型; F 为指示函数; S 为待检图像样本集合总数, 若给定的布尔表达式为真, 其值为 1, 反之则为 0。

② 斯皮尔曼等级相关系数。该系数越高, 算法对于测试图像的分类性能越好, 其具体计算过程如下:

$$\rho = 1 - \frac{6 \sum_{i \in S} I(r(i) - \hat{r}(i))^2}{|S| \times (|S|^2 - 1)} \quad (19)$$

式中 $f(i)$ 和 $\hat{r}(i)$ 分别为待检图像的真实分类和预测分类结果。

③ 实时检测速度。在机器学习算法中, 实时检测速度通常指的是算法在处理数据时的处理速度。而在图像与视频处理过程中, 往往使用帧率 (Frames Per Second, FPS) 来衡量检测算法的实时性大小。较高的 FPS 表示系统能够更快地处理和显示图像。因此, 选择 FPS 来评价本文方法的检测实时性大小。

2 S-FCN 模型试验结果与分析

2.1 火灾图像数据获取与数据集构造

使用自制数据集进行模型的训练与性能测试,

自制数据集图像源于 Canon EOS80D 相机拍摄的真实火灾场景以及网上森林火灾图像库 2 部分。表 2 为自制数据集数据具体来源信息表, 数据库总计 7 775 张, 其中火灾图像 3 777 张, 常规图像 3 998 张。

表 2 自制数据集来源信息

Table 2 Information on the source of self-made datasets

火灾图像	常规图像
①红色背景火灾场景:晴天自然光+阴天自然光+暗箱无光	①红色背景非火灾场景:晴天自然光+阴天自然光+暗箱无光
②绿色背景火灾场景:晴天自然光+阴天自然光+暗箱无光	②绿色背景非火灾场景:晴天自然光+阴天自然光+暗箱无光
③蓝色背景火灾场景:晴天自然光+阴天自然光+暗箱无光	③蓝色背景非火灾场景:晴天自然光+阴天自然光+暗箱无光
④森林火灾图像库	④随机拍摄其他背景非火灾场景

对于火灾图像, 主要基于红色背景、绿色背景、蓝色背景在晴天自然光、阴天自然光、暗箱无光 3 种光照条件下进行火灾场景模拟, 各取 400 幅, 森林火灾图像库源于互联网收集的 400 幅图像, 其中随机抽取 177 幅, 总计 3 777 幅火灾场景图像。对于常规图像, 主要基于红色背景、绿色背景、蓝色背景在晴天自然光、阴天自然光、暗箱无光 3 种光照条件下进行常规场景模拟, 各取 400 幅, 然后随机拍摄日出、日落、校园外景、教学楼内室等类似于火灾场景的常规场景 398 幅, 总计 3 998 幅常规图像。

2.2 数据处理

2.2.1 颜色特征提取

1) RGB 色彩空间颜色特征提取。基于 RGB 色彩模式下颜色特征提取方法提取图像颜色特征, 共计 4 个特征。

2) Lab 色彩空间颜色特征提取。首先, 将数据集原始图像转化到 Lab 色彩空间; 其次, 基于 Lab 色彩空间下颜色特征提取方法提取图像颜色特征, 共计 3 个特征。

3) HSV 色彩空间颜色特征提取。首先, 将数据集原始图像转化到 HSV 色彩空间; 其次, 基于 HSV 色彩空间下颜色特征提取方法提取图像颜色特征, 共计 4 个特征。

2.2.2 数据降维

根据 RGB、Lab、HSV 色彩空间下提取的颜色特征, 以及多通道特征降维结果 (图 2), 最终确定火灾

图像检测颜色特征(表 3)。

表 3 颜色特征降维结果

Table 3 Color feature dimensionality reduction results

排序	序号	字段
①	X_{22}	RGB 模式下绿色通道颜色特征值
②	X_{32}	HSV 模式下饱和度通道颜色特征值
③	X_{23}	RGB 模式下蓝色通道颜色特征值
④	X_{21}	RGB 模式下红色通道特征值
⑤	X_{31}	HSV 模式下色调通道特征值
⑥	X_{12}	Lab 模式 b 通道颜色特征值
⑦	X_{24}	RGB 模式下三通道颜色特征方差
⑧	X_{34}	HSV 模式下三通道颜色特征方差
⑨	X_{11}	Lab 模式下 a 通道颜色特征值

2.3 试验配置

在试验中分别从火灾图像和常规图像中随机选取 70% 和 10% 的样本用于训练和验证,将剩余的 20% 的图像作为测试样本。基于深度学习框架 Tensorflow 对 160-S-FCN 网络模型进行训练和测试。在训练过程中,优化器选用 Adam,隐藏层激活函数选择 ReLU,输出层激活函数选择 Sigmoid,训练损失目标函数采用二元分类对数交叉熵损失函数,训练最大迭代次数为 2 000。

2.4 试验结果对比分析

在对比试验中,将文中方法与传统机器学习模型进行对比,对比模型包括粗略、中等、精细策树,线性、二次、三次、高斯等支持向量机,双层、三层等神经网络,其中对比模型具体参数信息见表 4—表 6。表 7 为传统机器学习模型与本文方法的性能指标对比结果。

表 4 不同决策树参数信息

Table 4 Parameter information of different decision trees

决策树类型	最大分裂数	分裂准则
粗略决策树	4	基尼多样性指数
中等决策树	20	
精细决策树	100	

表 5 不同支持向量机参数信息

Table 5 Parameter information of different SVM

SVM 类型	核函数	核尺度
线性 SVM	线性	自动
二次 SVM	二次	自动
三次 SVM	三次	自动
高斯 SVM	高斯函数	13

由表 7 可知:相比决策树类、支持向量机类、单层神经网络与双层神经网络等对比模型,文中针对

表 6 神经网络参数信息

Table 6 Parameter information of neural networks

类型	全连接大小	隐藏层尺寸	备注
双层	2	10,10	激活函数 ReLU 迭代次数 1000
三层	3	10,10,10	

表 7 精度性能对比

Table 7 Comparison of accuracy performance

方法		精度/%	相关系数
决策树类	粗略决策树	82.40	0.768 2
	中等决策树	85.00	0.792 5
	精细决策树	87.30	0.813 9
支持向量机类	线性 SVM	79.70	0.743 1
	二次 SVM	88.50	0.825 1
	三次 SVM	87.40	0.814 8
	高斯 SVM	81.30	0.758 0
神经网络类	双层神经网络	92.80	0.865 2
	三层神经网络	92.30	0.860 5
本文方法	160-S-FCN	93.82	0.874 7

复杂背景提出的多色彩空间下颜色特征降维的 S-FCN 网络火灾图像检测方法,在火灾图像检测的精度与斯皮尔曼相关系数上取得了较好效果。具体来说,文中方法在准确率和斯皮尔曼等级相关系数上分别为 93.82% 和 0.874 7,与双层神经网络相比,2 个指标上分别获得 1.07% 和 1.09% 的相对提升。

2.5 消融试验分析

2.5.1 不同激活函数的有效性分析

基于互信息量进行颜色特征组合检测精度的对比,能够有效寻找最佳组合特征,克服了基于多特征排列组合传统方法带来的高计算量以及盲操作性等问题。图 5 为不同激活函数下不同特征组合检测精度对比图。

由图 5 可知:①不同隐层尺寸下不同激活函数对于火灾图像检测结果具有相对稳定性,这表明本文所提出的方法对于复杂背景下的火灾图像检测具有较高可靠性。②随着单隐层尺寸从 10 层逐渐增加到 10 240 层,ReLU 和 Tanh 激活函数的检测性能均越来越稳定,其检测精度分别为 95.22%、93.93%。③从激活函数的有效性方面看,ReLU 激活函数比 Tanh 激活函数检测精度更高;对于 Logistic 激活函数而言,随着隐层尺寸逐渐增加,其检测精度先增高后降低,且其稳定性相对较差;对于 Identity 激活函数而言,随着隐层尺寸的增加,其检测性能也越来越稳定,但其精度相较于上述 3 类激活函数明显处于劣势。

2.5.2 不同隐层尺寸的有效性分析

单隐层尺寸大小对火灾图像检测有效性具有较

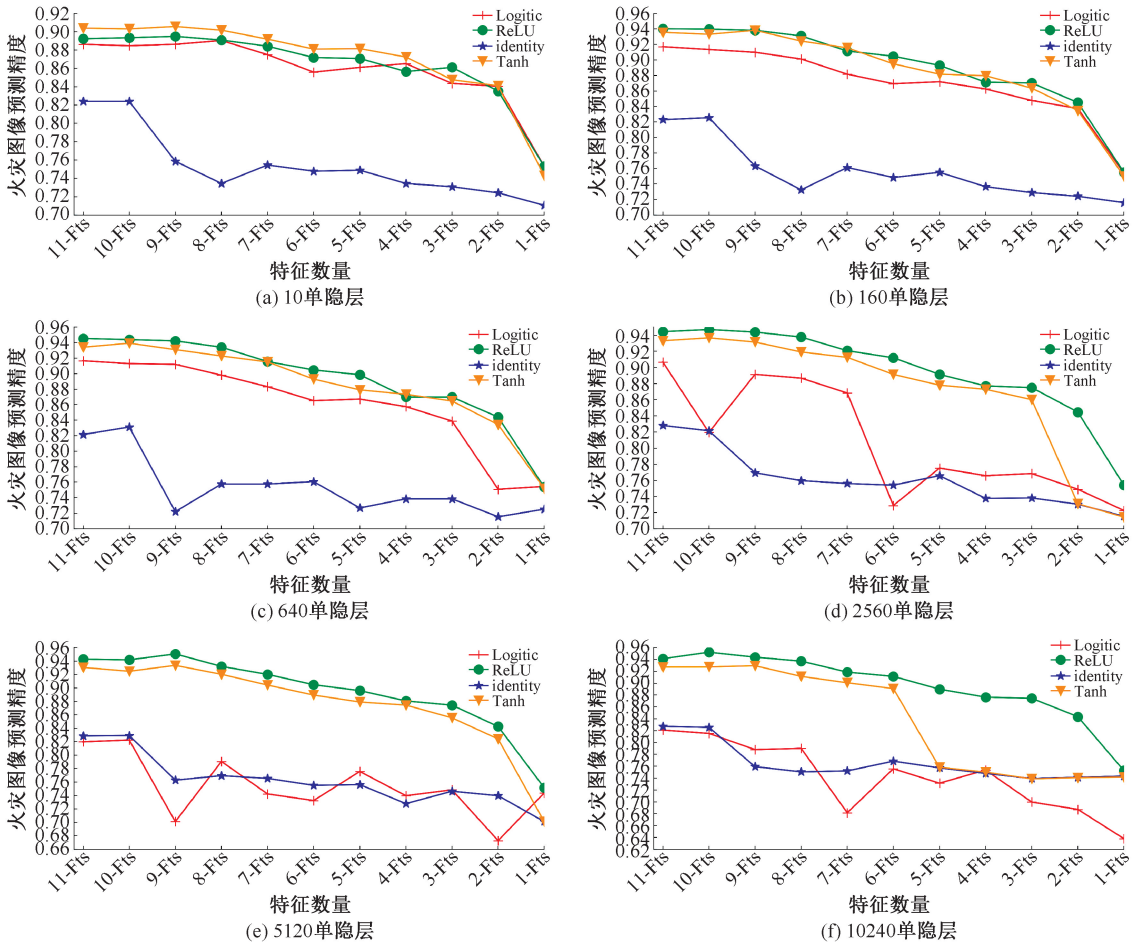


图 5 不同激活函数下不同特征组合的有效性分析

Fig. 5 Effectiveness analysis of different feature combinations under different activation function

大影响,图 6 为不同隐层尺寸对火灾图像检测的有效性对比结果。

由图 6 可知:①随着单隐层尺寸的增加,模型的检测精度先增加后降低,当单隐层尺寸增加至 160~320 时,火灾图像检测精度达到最高(93.82%)。②当单隐层数为 160 时,图像的检测结果与真实结果的皮尔曼相关系数最高(0.874 7),这与该网络结构下火灾图像检测精度最高具有高度一致性。③在训练成本方面,随着单隐层尺寸从 10 增加至 20 480 时,训练时间成本呈现指数增加态势;当单隐层数为 160 时,训练时间为 256 s,计算成本为 20 480 隐层模型的 0.67%。因此,当单隐层尺寸为 160 时,对于复杂背景下火灾图像检测的精度、斯皮尔曼相关系数最高,训练时间成本也相对较小,模型的综合性能达到最优。

2.5.3 不同优化函数的有效性分析

深度神经网络的参数学习主要通过梯度下降法来寻找一组可以最小结构风险的参数,优化函数梯度下降可以分为批量梯度下降、随机梯度下降、小批

量梯度下降 3 种形式。图 7 为常见 3 种不同优化函数的有效性对比结果。

由图 7 可知:在预测精度上,Adam、lbfgs、sgd 优化函数分别为 93.82%、94.44%、86.84%;但对于 lbfgs 优化器,随着迭代次数的增加产生了过拟合现象,Adam 优化器在训练过程中稳定性较好,未产生过拟合现象。在斯皮尔曼相关系数上,Adam、sgd、lbfgs 优化函数分别达到了 0.884 4、0.758 7、0.862 8;在训练时间成本上,Adam、sgd、lbfgs 优化函数分别为 1 623.15、1 397.13、1 328.23 s (迭代次数均为 1 000)。综上所述,在训练成本上 lbfgs、sgd 优化器均明显低于 Adam 优化器,lbfgs 较 Adam 优化器降低了 13.92%,sgd 较 Adam 优化器降低了 18.17%;但在预测精度的稳定性、斯皮尔曼相关系数等指标上,Adam 优化器明显优于 lbfgs、sgd 优化器。

2.5.4 特征组合类型与隐层尺寸大小匹配度分析

图 8 为 ReLU 激活函数下特征组合类型与隐层尺寸大小匹配度可视化图。由图 8 可知:对于性能

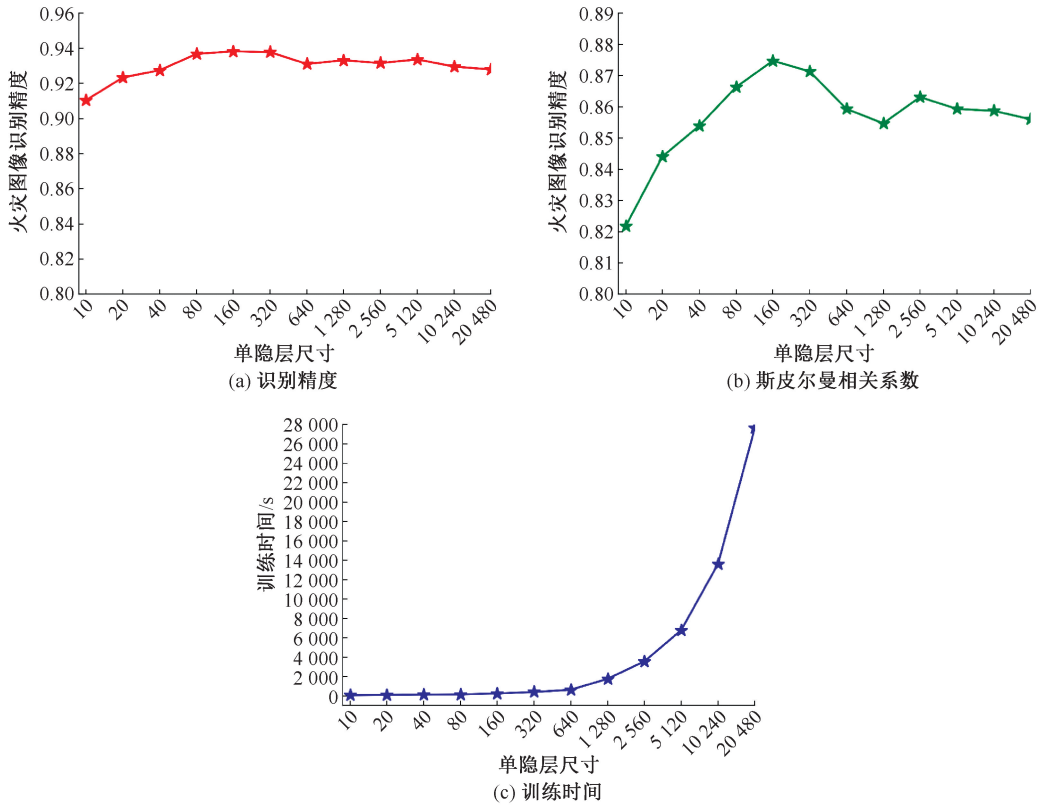


图 6 单隐层尺寸大小的有效性对比结果

Fig. 6 Effectiveness comparison results of single hidden layer size

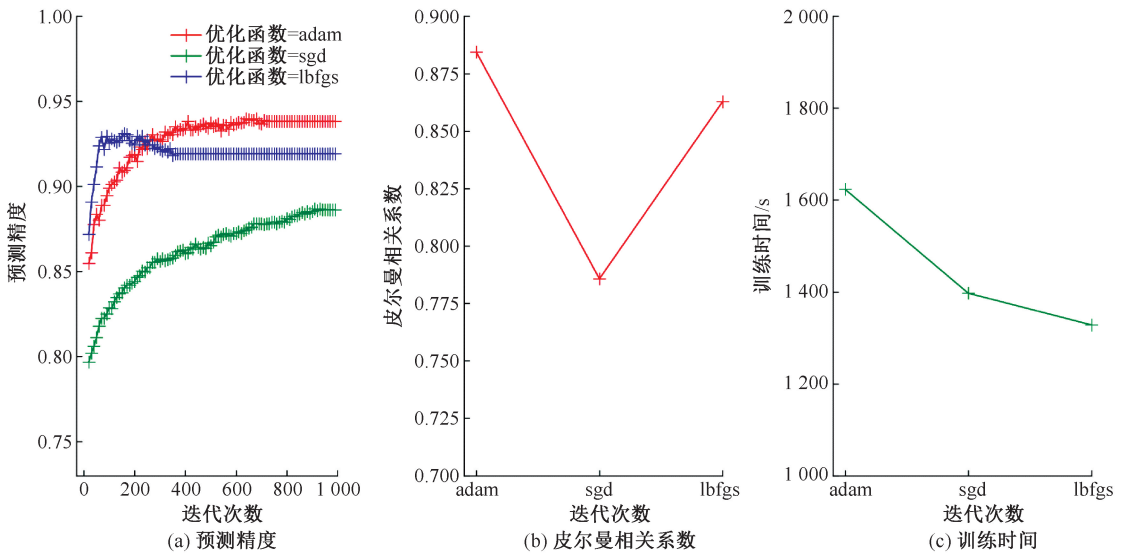


图 7 不同优化函数的有效性对比结果

Fig. 7 Comparison results of the effectiveness of different optimization functions

最好的 ReLU 激活函数而言,9 特征组合整体检测精度最高、稳定性较好;10 特征组合整体精度也较高,但稳定性相较于 9 特征稍差;11 特征、8 特征、7 特征相较于 9 特征从整体精度及稳定性方面均明显处于劣势。因此,ReLU 激活函数下的 9 特征组合为最佳特征组合。对于性能最好的 ReLU 激活函数而

言,随着单隐层尺寸的增加,其预测精度性能也随之增加,但由图 5 单隐层尺寸大小的有效性对比结果可知,随着隐层尺寸的增加,其训练时间成本也呈指数增长,从训练时间成本与预测精度 2 个角度综合考虑,单隐层尺寸为 160 的网络训练成本为 256 s,其精度为 93.82%;相较于单隐层尺寸为 640 的网

络,其精度提高了 0.7%,但训练成本降低了 85%。因此,ReLU 激活函数下的单隐层尺寸为 160 的全连接网络为最佳预测网络结构。

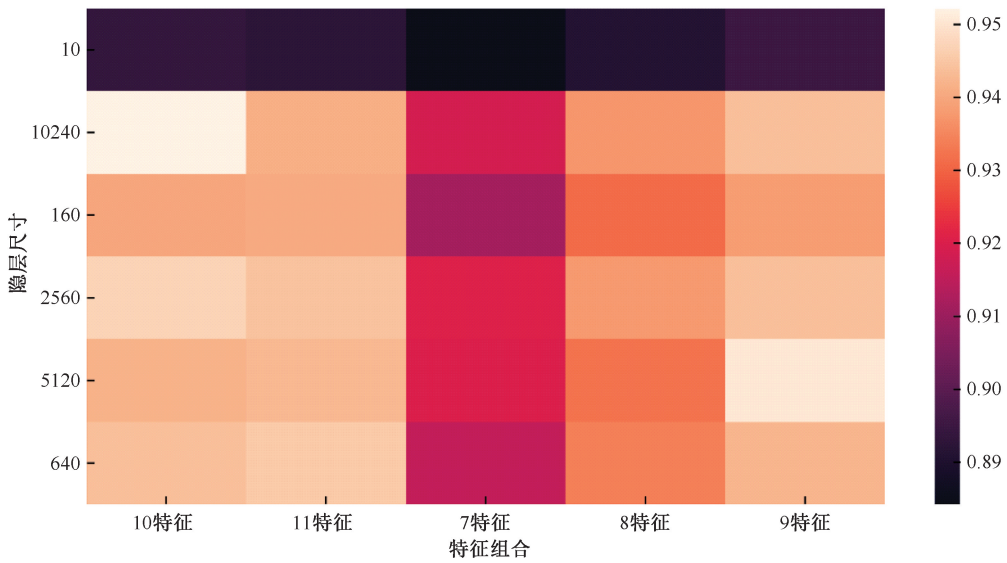


图 8 ReLU 激活函数下特征组合类型与隐层尺寸大小匹配度可视化图

Fig. 8 Visual diagram of matching degree between feature combination type and hidden layer size under ReLU activation function

3 结 论

1) 针对复杂背景下火灾图像检测问题,提出一种基于特征工程的轻量型神经网络模型。该模型网络结构模块使用 160-S-FCN,进一步压缩了网络结构,减少模型的参数数量,更进一步提升了检测实时性能。

2) 文中方法的检测精度和检测速度分别为 93.82%和 10 869 帧/s,可实现检测速度和精度 2 方面性能的同时提升。虽然在检测精度上提升了 1.07%,但是在实时性上提升了约 1.1 倍,参数数量上更是降低 50%,这能够更好地保证在复杂背景下

精准高效地检测火灾。

3) 针对文中方法训练出的模型还进行了消融试验。消融试验结果表明:该模型具有较高的鲁棒性与稳定性,针对昏暗、阴天、日出、室内等复杂场景下火灾图像检测仍然具有较高的检测精度,实现了在复杂环境中快速鲁棒检测火灾。

4) 文中方法主要适用中等尺度及以上火灾烟雾与火焰图像的识别,尤其对于火焰图像的识别精度更高。下一步将重点针对小尺度火灾烟雾与火焰目标,融合纹理、形状等多维特征开展算法改进和优化研究。在数据集制作上,主要采集相应背景下的小尺度烟雾与火焰火灾图像。

参 考 文 献

[1] 王子辰,陈晓艳,王倩,等. 基于残差自注意力连接的深度电学层析成像方法[J]. 仪器仪表学报, 2023, 44(5): 288-301.
WANG Zichen, CHEN Xiaoyan, WANG Qian, et al. Deep electrical tomography imaging method based on residual self-attention connection [J]. Journal of Instrumentation, 2023, 44 (5): 288-301.

[2] 李丹,王慢慢,刘俊德,等. 基于轻量级卷积神经网络的带钢表面缺陷识别[J]. 仪器仪表学报, 2022, 43(3): 240-248.
LI Dan, WANG Manman, LIU Junde, et al. Surface defect identification of strip steel based on lightweight convolutional neural networks [J]. Journal of Instrumentation, 2022, 43 (3): 240-248.

[3] 杨其睿. 基于改进的 DenseNet 深度网络火灾图像识别算法[J]. 计算机应用与软件, 2019, 36(2): 258-263.
YANG Qirui. Improved densenet deep network fire image recognition algorithm [J]. Computer Application and Software, 2019, 36 (2): 258-263.

- [4] YANG Yi, PAN Mengyi, LI Pu, et al. Development and optimization of image fire detection on deep learning algorithms[J]. *Journal of Thermal Analysis and Calorimetry*, 2023, 148(11): 5 089–5 095.
- [5] VENANCIO D, LISBOA A C, BARBOSA A V. An automatic fire detection system based on deep convolutional neural networks for low-power, resource-constrained devices [J]. *Neural Computing and Applications*, 2022, 34(18): 15 349–15 368.
- [6] MAJID S, ALENEZI F, MASOOD S, et al. Attention based CNN model for fire detection and localization in real-world images[J]. *Expert Systems with Applications*, 2022, 189: DOI: 10.1016/j.eswa.2021.116114.
- [7] KHAN A, HASSAN B, KHAN S, et al. DeepFire: a novel dataset and deep transfer learning benchmark for forest fire detection[J]. *Mobile Information Systems*, 2022, 2022(6): DOI: 10.1155/2022/5358359.
- [8] DOGAN S, BARUA P D, KUTLU H, et al. Automated accurate fire detection system using ensemble pretrained residual network[J]. *Expert Systems with Applications*, 2022, 203: DOI: 10.1016/j.eswa.2022.117407.
- [9] PINCOTT J, TIEN P W, WEI S, et al. Indoor fire detection utilizing computer vision-based strategies[J]. *Journal of Building Engineering*, 2022, 61: DOI: 10.1016/j.job.2022.105154.
- [10] MUKHIDDINOV M, ABDUSALOMOV A B, CHO J. Automatic fire detection and notification system based on improved yolov4 for the blind and visually impaired[J]. *Sensors*, 2022, 22(9): DOI: 10.3390/s22093307.
- [11] DILSHAD N, KHAN T, SONG J. Efficient deep learning framework for fire detection in complex surveillance environment[J]. *Computer Systems Science and Engineering*, 2023, 46(1): 749–764.
- [12] AN Qing, CHEN Xijiang, ZHANG Junqian, et al. A robust fire detection model via convolution neural networks for intelligent robot vision sensing[J]. *Sensors*, 2022, 22(8): DOI: 10.3390/s22082929.
- [13] AHN Y, CHOI H, KIM B S. Development of early fire detection model for buildings using computer vision-based CCTV[J]. *Journal of Building Engineering*, 2023, 65: DOI: 10.1016/j.job.2022.105647.
- [14] HUANG Lida, LIU Gang, WANG Yan, et al. Fire detection in video surveillances using convolutional neural networks and wavelet transform[J]. *Engineering Applications of Artificial Intelligence*, 2022, 110: DOI: 10.1016/j.engappai.2022.104737.
- [15] KHAN Z A, HUSSAIN T, ULLAH F U M, et al. Randomly initialized CNN with densely connected stacked autoencoder for efficient fire detection [J]. *Engineering Applications of Artificial Intelligence*, 2022, 116: DOI: 10.1016/j.engappai.2022.105403.
- [16] MAHMOUD H A, ALHARBI A H, ALGHAMDI N S. Time-efficient fire detection convolutional neural network coupled with transfer learning[J]. *Intelligent Automation & Soft Computing*, 2022, 31(3): 1 393–1 402.
- [17] LI Yuming, ZHANG Wei, LIU Yanyan, et al. A visualized fire detection method based on convolutional neural network beyond anchor[J]. *Applied Intelligence*, 2022, 52(11): 13 280–13 295.
- [18] ZHANG Rong, ZHANG Wei, LIU Yanyan, et al. An efficient deep neural network with color-weighted loss for fire detection[J]. *Multimedia Tools and Applications*, 2022, 81(27): 39 695–39 713.
- [19] 赵超, 陈肇泉, 王斌, 等. 基于互信息和 IGSA 优化 ELM 的重整芳烃收率软测量[J]. *仪器仪表学报*, 2019, 40(3): 255–263.
- ZHAO Chao, CHEN Zhaoquan, WANG Bin, et al. Soft sensing of reforming aromatics yield based on mutual information and IGSA optimized ELM [J]. *Journal of Instrumentation*, 2019, 40(3): 255–263.
- [20] 夏鹏飞, 尹慧琳, 何艳侠. 基于最大互信息的激光雷达与相机的配准[J]. *仪器仪表学报*, 2018, 39(1): 34–41.
- XIA Pengfei, YIN Huilin, HE Yanxia. Registration of lidar and camera based on maximum mutual information [J]. *Journal of Instrumentation*, 2018, 39(1): 34–41.



作者简介: 李海 (1989—),男,甘肃定西人,博士研究生,讲师,主要从事机器视觉、图像处理、智能模式识别方面的研究。E-mail: lihai@cafuc.edu.cn。