

引用本文

李璞,张苗.图像复杂度驱动的火灾探测算法评估方法[J].消防科学与技术,2026,45(5):87—93.

Li Pu,Zhang Miao.Image fire detection algorithms evaluation methods based on image complexity[J].Fire Science and Technology,2026,45(5):87—93.

图像复杂度驱动的火灾探测算法评估方法

李 璞¹, 张 苗²

(1. 郑州航空港经济综合实验区消防救援支队, 河南 郑州 450000;

2. 天津市和平区消防救援支队, 天津 300000)

摘 要: 本文引入“图像复杂度”, 度量图像型火灾探测算法从图像中识别火灾的难易程度。通过程序测试法获取“人类响应时间”, 界定数据集中图像复杂度真实值。在此基础上, 利用卷积神经网络开发能够自动预测全图综合复杂度的评估器。一致性分析后发现, Inception ResNet-v2 评估器生成的全图综合复杂度度量指标表现出最高的有效性, 进而提出基于图像复杂度的图像型火灾探测算法性能评估方法。该方法能够更准确地评估探测算法在不同“图像复杂度”条件下所能达到的探测水平, 为火灾探测算法的开发与优化提供了重要参考。

关键词: 图像复杂度; 火灾探测; 卷积神经网络

中图分类号: X932; X924.4 **文献标志码:** A **DOI:** 10.20168/j.1009-0029.2026.05.0087.07

Image fire detection algorithms evaluation methods based on image complexity

Li Pu¹, Zhang Miao²

(1. Zhengzhou Airport Economy Zone Fire and Rescue Division, Zhengzhou Henan 450000, China; 2. Heping Fire and Rescue Division of Tianjin, Tianjin 300000, China)

Abstract: The "image complexity" is proposed to measure the difficulty for the algorithm to detect fire in an image. The "human response time" is obtained through the program test method, which could define the true value of the complexity of the image in the data set. Then, convolutional neural network is used to develop an evaluator that can automatically predict the comprehensive complexity of the whole image. Through the consistency analysis, the comprehensive complexity measure of the whole image generated by the Inception ResNet-v2 evaluator is the most effective measure. Furthermore, a performance evaluation method based on image complexity is proposed. This method can evaluate the detection level that the algorithm can achieve under different "image complexity" situations more accurately, providing more valuable reference for the development and optimization of fire detection algorithms.

Key words: image complexity; fire detection; convolutional neural network

目前, 国内外现有的图像型火灾探测器的标准^[1-3]未充分考虑到该技术以图像数据为分析对象的独特性, 仍沿用传统的探测器测试方法。这些测试方法生成的图像场景较为简单, 与实际应用中需要分析的图像信息存在显著差异, 难以有效区分探测算法的优劣, 因而并不适用于图像型火灾探测算法的性能

评价。

当前, 相关研究通常采用几组真实火灾图像或干扰图像, 通过计算探测率或误报率来评估火灾探测算法性能^[4-12]。然而, 由于图像型火灾探测算法以图像为分析对象, 不同图像的内容复杂度差异较大, 导致算法在识别不同火灾图像时的难易程度不尽相同。

作者简介: 李璞, 郑州航空港经济综合实验区消防救援支队, 主要从事消防安全方面的研究, 河南省郑州市郑东新区正光路11号河南省教育厅安全管理处, 450000, 540537194@qq.com。

收稿日期: 2025-02-20; **修回日期:** 2025-10-09

这种差异使得同一算法在不同图像数据集上的评估结果可能存在显著差异,如ÇELIK T等提出的基于YCbCr颜色空间的火焰探测算法,其探测率在不同研究中从58.3%到99%不等。

由于缺少有效的算法评估方法,许多在研究阶段表现优异的算法在实际应用中却表现平平。这制约了图像型火灾探测技术的发展与应用。因此,亟待开发一种能够结合图像数据特性和火灾探测特点的算法性能评估方法,以更准确地衡量探测算法在实际应用中的探测能力。相较于传统的评估方法和仅扩充数据集的评估方法,该方法应能够更全面地分析算法在不同火灾探测难度下的探测性能,从而为火灾探测算法的开发与优化提供科学依据。

1 图像复杂度的提出

与传统火灾探测方法不同,图像型火灾探测算法以图像数据为研究对象,而不同的图像是在不同条件下拍摄的,涵盖的内容也不尽相同。因此,同一算法对不同图像进行火灾探测时,探测的难易程度也不相同。这就导致在有限的图像数据条件下,探测算法的性能评估结果同时取决于该算法的真实性能和用于怎样的探测难度。为衡量算法从图像中探测火灾的综合难易程度,本文借鉴红外目标识别和图像识别领域的相关研究,引入“图像复杂度”^[13]作为评估火灾探测算法性能的关键指标。“图像复杂度”是指在完成某项图像处理任务(如目标识别、图像恢复、图像压缩、图像水印等)时,图像内在信息的复杂程度。在火灾探测领域,“图像复杂度”则是指在环境光、类似火源干扰物、遮挡、分辨率、信噪比等因素的影响下,算法从图像中探测火灾的难易程度。上述这些影响因素表现为不同的图像特征,即“图像复杂度”是任何影响探测算法性能的图像特征的组合。

2 图像复杂度真值的界定

人们在观察图1时,通常会直观地认为图1(a)的图像复杂度小于图1(c)的复杂度,为量化这一主观判断,本文结合图像识别领域的人工标注和IONESCURI T等^[14]的思想,利用“人类响应时间”对图像复杂度进行量化评分,并将评分范围设置为[0,1],以此作为图像复杂度真值。



图1 不同图像的图像复杂度得分

Fig. 1 Image complexity scores for different images

为收集“人类响应时间”数据,基于微信平台开发

了一款小程序,并利用李璞等^[15]建立的火灾图像数据集进行试验,数据收集过程主要遵循以下协议。

1)向被测试人员询问以下问题:“您看到的图像中是否存在{火灾,火焰,烟气}?”。

2)向被测试人员展示测试图像。

3)记录被测试人员回答“是”或“否”的时间,作为该图像的人类响应时间。

为了确保记录的响应时间真实可靠,被测试人员需要在阅读问题后点击“确认按钮”才能看到测试图像;每张图像只能被同一人员测试1次;每张图像收集至少3个独立响应时间。最终,经过数据预处理剔除不合格数据后,共收集535名测试人员对29180张图像的87540个测试结果。每张图像的“人类响应时间”取所有测试结果的平均值。

在数据收集过程中,允许被测试人员存在最高10%的识别错误率。识别错误从一定程度上反映了图像的高复杂度,为避免其对评分结果产生过大影响,对错误响应时间施加了惩罚机制,即将错误响应时间按1.5倍计入最终结果。

将收集的图像“人类响应时间”合并后,采用式(1)归一化处理,作为火灾探测的图像复杂度真值。

$$Dif = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中: x 为图像的“人类响应时间”; $x_{\min}$ 为收集到的火灾图像数据集中图像“人类响应时间”最小值; $x_{\max}$ 为最大值。

图2为本文建立的火灾图像数据集中图像的复杂度分布直方图。




图2 火灾图像数据集中不同图像复杂度水平的样本分布

Fig. 2 Sample distribution of different levels of image complexity in the fire image dataset

3 图像复杂度的度量方法

从算法性能评估的角度考虑,图像复杂度的度量指标应当遵守以下原则:度量指标生成的预测值应与图像复杂度真值密切相关;与算法的特征提取相比,度量指标应当涵盖更多的探测条件;指标的计算应该相对简单,能够快速获取。

在红外识别领域和图像识别领域,图像复杂度的

度量方法研究一般采用人工设计提取图像特征指标,常用的有全局背景环境度量指标、目标/背景差异(相似)度量指标、目标/干扰差异度量指标3种,主要通过图像特征直方图计算。但影响算法探测性能的因素呈现出的图像特征成千上万,既包括目标、干扰事件的图像特征,也包括背景的图像特征,人工提取的图像特征是非常有限的,仅能总结几类以往研究中发现的、对图像探测影响较大的特征,作为度量图像复杂度的指标,想要综合度量各种探测条件非常困难。因此,本文提出利用深度学习网络可以自动学习图像特征的优势,训练图像探测条件提取器,对图像复杂度进行打分,自动生成全图综合复杂度。

全图综合复杂度度量指标描述背景、目标、干扰事件等所有影响算法火灾探测性能的因素构成的综合图像特征。将常用的深度卷积神经网络(VGG-16^[16]、ResNet-18、ResNet-101、ResNet-152^[17]、Inception-v3^[18]、Inception-v4、Inception ResNet-v2^[19]、Xception^[20]、MobileNet-v1^[21]和 MobileNet-v2)作为复杂度评估模型的基础架构,开发全图综合复杂度评估器,自动对图像的探测复杂度进行评价,并利用上文生成的图像复杂度真值进行训练。

图3为复杂度评估器的基本架构,前端为基于卷积神经网络的图像探测条件提取网络,用于提取图像特征作为探测条件,后端为复杂度评估网络。




图3 全图综合复杂度评估器

Fig. 3 Comprehensive complexity evaluator for the entire graph

构建模型时,保留这些CNN网络前端的特征提取网络作为探测条件提取网络,后端的复杂度生成网络由全连接层和Sigmoid函数组成,即原将CNN网络后端的Softmax函数由Sigmoid函数代替。训练模型时,采用预训练好的网络进行迁移学习,冻结特征提取网络,采用含图像复杂度真值的火灾图像数据集,对复杂度生成网络进行训练。

4 度量方法的有效性研究

为验证度量指标的有效性,选取李璞等建立的火灾图像数据测试集中的图像,分别计算每个图像的全局背景环境度量指标值、目标/背景差异(相似)度量指标值、目标干扰差异度量指标值和全图综合复杂度

度量指标值。然后将前文取得的图像复杂度真值分别与度量指标值进行比较,讨论两组数据间的相关性,从而研究本文提出的度量方法的有效性。

图4为前文得到的测试集中14 590张测试图像的图像复杂度真值。






图4 测试集的图像复杂度真值

Fig. 4 True image complexity of test set

图5为采用本文提出的度量方法预测的图像复杂度,限于篇幅,仅列举了基于Inception ResNet-v2、MobileNet-v1的全图综合复杂度度量指标值。



(a)基于 Inception ResNet-v2的评估器



(b)基于 MobileNet-v1的评估器

图5 图像复杂度预测值

Fig. 5 Estimated image complexity

分析可知,预测值与复杂度真值的变化趋势基本一致。图6为图像复杂度真值与预测值的关系图。图中红色直线为图像复杂度真值采用最小二乘法对

预测值进行线性拟合得到的拟合线。根据线性回归原理可知,拟合线 $y = a + bx$ 斜率的绝对值 $|b|$ 越接近1,预测值与真值的变化规律越接近,相关性越强,即预测结果越理想。可知基于Inception ResNet-v2的全图综合复杂度度量指标值拟合线斜率为0.81,相较基于MobileNet-v1指标的0.66更为理想。




图6 图像复杂度真值和预测值之间的相关性

Fig. 6 Correlation between true and predicted image complexity values

分析图4可知,测试集中70%以上图像的图像复杂度真值取值在 $[0, 0.2]$ 之间。因此,当采用某种度量方法使所有预测值都在 $[0, 0.2]$ 区间时,预测结果的平均误差可能相对较低。但这样趋于一致的预测值却不能很好地区分不同图像对于算法探测火灾难易程度的影响。而图像复杂度的度量,最主要是考察度量方法是否能够有效区分不同图像对于算法探测火灾的真实难易程度的影响。因此,理想的度量方法应当是,根据预测值大小对图像的排序结果与根据真值对图像的排序一致。为了定量比较不同度量方法的有效性,采用Kendall τ 相关系数^[22]考察预测值与图像复杂度真值对图像排序的一致性。

分别根据图像复杂度真值和4种图像复杂度度量指标生成的复杂度对测试集中的图像进行排序。然后,计算真值和各预测值排序之间的Kendall τ 相关系数,如表1所示。其中,目标/背景差异(相似)度量指标仅对测试集中的火灾图像进行度量;目标/干扰

差异度量指标仅对测试集中存在干扰事件的非火灾图像进行度量,如果一张图像中存在多个干扰事件,则分别计算后取平均值;Kendall τ 相关系数取负值时,代表度量指标值与复杂度负相关,即指标值越小,图像复杂度越大,如目标/背景差异度量指标值与图像复杂度真值负相关,代表目标与背景差异越小,图像复杂度越大;全图综合复杂度由基于不同CNN网络的评估器生成。

表1 不同图像复杂度度量指标值的相关性

Table 1 Correlation of different image complexity metrics values

图像复杂度指标			Kendall τ 相关系数	排序一致性
全局背景环境度量指标	灰度均值		0.112	56%
	灰度标准差		0.106	55%
	灰度能量		0.195	60%
	灰度熵		0.218	61%
目标/背景差异（相似）度量指标	目标/背景差异度量指标	R	-0.387	69%
		G	-0.316	66%
		B	-0.148	57%
	目标/背景相似度度量指标	RGB	0.398	70%
		HIS	0.451	73%
目标/干扰差异度量指标	类似火源干扰事件	R	-0.279	64%
		G	-0.231	62%
		B	-0.151	58%
	类似烟气干扰事件	R	-0.213	61%
		G	-0.238	62%
		B	-0.122	56%
全图综合复杂度度量指标	VGG-16		0.546	77%
	ResNet-18		0.493	75%
	ResNet-101		0.646	82%
	ResNet-152		0.666	83%
	Inception-v3		0.650	82%
	Inception-v4		0.682	84%
	Inception ResNet-v2		0.695	85%
	Xception		0.676	83%
	MobileNet-v1		0.490	75%
	MobileNet-v2		0.536	77%

由表1可知,本文提出的图像复杂度度量指标预测值均与复杂度真值存在一定相关性。整体而言,全局背景环境度量相较另外3种度量指标相关性最低,这主要是因为其仅考虑了背景因素,且只简单计算了背景的灰度条件;目标/背景相似度度量指标由于综合考虑了颜色、纹理相似度,是人工设计的度量指标里表现最好的,达到了70%以上的一致性。但是,该指标仅能用于度量火灾图像的复杂度。

分析全图综合复杂度度量指标预测值的相关性可知,即使是模型复杂度最低的MobileNet系列模型

构建的评估器,产生的预测值的Kendall τ 相关系数也能达到0.490,具有较强的相关性。通过机器自动生成的“全图综合复杂度”排序的顺序与基于人工评判得到的复杂度真值的排序一致性达75%以上。其中,基于Inception ResNet-v2网络架构的评估器表现最好,排序一致性达85%。结果表明,本文提出的全图综合复杂度评估器对图像复杂度达到了较理想的预测效果。

另外,通过对比人工设计的度量指标和机器自动生成的度量指标发现,前者生成的预测值均不及后者优越。这从侧面证明,只考虑一种或几种探测条件的人工设计的度量指标很难准确度量图像复杂度。有效度量复杂度需要提取更复杂、更高层次的图像特征,而人工设计的度量指标仅能提取低级或中级图像特征。基于深度学习的CNN网络能通过提取高层图像特征,同时对图像的背景、目标及干扰信息进行度量。因此,本文提出的基于图像复杂度的算法评估方法主要采用全图综合复杂度度量指标预测图像复杂度。

5 基于图像复杂度的算法评估

基于图像复杂度的算法度量方法用于评估算法在不同复杂度水平下的性能,其具体实施流程如下。

1)根据评估目标选择评估指标,如探测率、误报率等;

2)根据评估目标设定图像复杂度水平;

3)根据1)、2)选择测试图像数据,测试图像可以根据Inception ResNet-v2评估器预测的全图综合复杂度,从已建立的火灾图像数据集中选取,也可以根据需要通过场外试验、网络搜索等方式收集,新收集图像的复杂度通过基于Inception ResNet-v2的评估器生成;

4)将测试图像输入待评估的算法,得到该算法在设定的图像复杂度水平下所能达到的探测性能 $P(X|Y=y)$,其中 X 代表输入算法的测试图像数据集, $Y=y$ 代表设定的图像复杂度水平。

基于图像复杂度的算法度量方法如图7所示。




图7 基于图像复杂度的算法评估

Fig. 7 Algorithm evaluation based on image complexity

5.1 传统算法的评估测试

为考察算法在不同图像复杂度水平下的探测性

能,选取李璞等建立的火灾图像数据测试集中,标注<sequence>取值为1的图像,组成数据集Testset1进行测试,对MUHAMMAD K等^[4],ÇELIK T等^[5],CHEN T H等^[6],RONG J Z等^[7]和严云洋等^[8]的5种算法的探测性能进行评估,其中前4种算法为基于人工提取火灾图像特征的算法,MUHAMMAD K等的算法为基于深度卷积神经网络(GoogLeNet)自动提取火灾图像特征的算法。

依据图像复杂度水平将Testset1划分成6个区间:[0,0.1)、[0.1,0.2)、[0.2,0.3)、[0.3,0.4)、[0.4,0.6)、[0.6,1.0]。由前文可知,本文采用的火灾图像数据集中,低探测复杂度数据相对较多,因此对低复杂度进行了细分。然后,将Testset1中的图像根据基于Inception ResNet-v2的评估器预测的全图综合复杂度分成6个测试子集,详见表2。

表2 测试子集的基本情况

Table 2 Basic information of the test subset

测试子集	复杂度	图像	火灾图像(含火焰)	非火灾图像
Testset1-1	[0,0.1)	183	121	62
Testset1-2	[0.1,0.2)	812	201	611
Testset1-3	[0.2,0.3)	1 613	652	961
Testset1-4	[0.3,0.4)	1 137	275	862
Testset1-5	[0.4,0.6)	923	439	484
Testset1-6	[0.6,1.0]	347	118	229

将Testset1中的图像分别输入探测算法,估算不同复杂度水平下算法的探测率和误报率。表3为5种算法在6个图像复杂度水平下的探测率和误报率。

通过分析表3发现,基于机器自动提取图像特征的MUHAMMAD K等的算法由于提取了高层次图像特征进行火灾探测,因此在各种图像复杂度水平下均能保持相对较高的探测率和较低的误报率。基于人工提取火灾图像特征的严云洋等的算法在利用低层次的颜色特征的同时,又采用累积差分的方法利用了中层次的闪频特征,因此在图像复杂度小于0.4时,探测率和误报率相较其他3种算法表现较好。但是由于仅利用了中层次特征,在图像复杂度大于0.4的情况下,探测率下降较多,误报率也较高。因此,该算法不能应对复杂的应用场景。而仅提取了低层次颜色特征的ÇELIK T等的算法仅能在复杂度小于0.2的情况下保持一定的探测率。

通过评估发现,基于深度卷积神经网络的探测算法能够自动提取高层次图像特征,更适用于复杂场景(如商场、饭店、城镇街道等)的火灾探测。此外,算法的探测性能在不同图像复杂度水平下差异较大,探测率会随着图像复杂度的增加而减小,误报率随着复杂度的增加而增大。

表3 算法在不同复杂度水平下的探测性能

Table 3 Detection performance of algorithms at different complexity levels

算法性能		图像复杂度水平					
		[0,0.1)	[0.1,0.2)	[0.2,0.3)	[0.3,0.4)	[0.4,0.6)	[0.6,1.0]
探测率	ÇELİK T等 ^[5]	90.91%	88.06%	79.75%	76.36%	60.80%	50.85%
	CHEN T H等 ^[6]	95.04%	94.03%	93.25%	90.91%	70.35%	59.32%
	RONG J Z等 ^[7]	96.69%	93.53%	89.42%	80.36%	63.32%	52.54%
	严云洋等 ^[8]	97.52%	96.02%	96.17%	94.55%	69.35%	61.02%
	MUHAMMAD K等 ^[4]	98.35%	96.52%	95.55%	93.82%	89.45%	78.81%
误报率	ÇELİK T等 ^[5]	33.10%	57.94%	67.33%	76.10%	78.87%	89.52%
	CHEN T H等 ^[6]	50.34%	52.86%	76.69%	75.87%	87.71%	88.21%
	RONG J Z等 ^[7]	11.72%	27.17%	35.48%	67.87%	72.10%	69.00%
	严云洋等 ^[8]	8.97%	18.17%	29.24%	27.26%	48.07%	54.59%
	MUHAMMAD K等 ^[4]	4.83%	11.13%	15.92%	13.46%	17.82%	26.64%

5.2 基于目标检测卷积神经网络的算法评估测试

为进一步考察本文提出评估方法的有效性,本节采用李璞等^[15]建立的火灾图像数据测试集中所有图像作为Testset2对张苗等^[9]提出的基于目标检测卷积神经网络(Faster-RCNN、R FCN、SSD、YOLO v3和YOLO v8s)的10种算法进行评估,表4为10种算法不同图像复杂度水平下的平均精度及独立性指标值(IND)。

表4 不同图像复杂度水平下探测算法的平均精度及独立性指标值

Table 4 Average accuracy and IND of detection algorithms at different levels of image complexity

算法	探测类别	不同图像复杂度水平下的算法平均精度					IND	
		[0,0.1)	[0.1,0.2)	[0.2,0.4)	[0.4,0.6)	[0.6,1.0]		
Faster-RCNN-1	火灾	85.0%	80.7%	80.5%	75.3%	73.9%	0.78	
Faster-RCNN-2	烟气	84.3%	80.6%	78.9%	77.3%	73.1%	0.64	0.57
	火焰	86.6%	84.3%	82.1%	81.9%	77.3%	0.50	
R-FCN-1	火灾	82.8%	79.1%	76.5%	72.2%	70.7%	0.87	
R-FCN-2	烟气	83.5%	77.5%	75.3%	71.6%	68.1%	1.19	1.01
	火焰	85.7%	83.3%	80.1%	76.7%	74.3%	0.83	
SSD-1	火灾	81.9%	74.7%	70.4%	68.1%	65.2%	1.37	
SSD-2	烟气	78.1%	73.2%	70.0%	65.8%	60.2%	1.59	1.66
	火焰	84.3%	81.5%	78.3%	72.5%	67.4%	1.72	
YOLO v3-1	火灾	87.2%	84.5%	81.7%	80.6%	78.4%	0.48	
YOLO v3-2	烟气	84.5%	82.7%	80.3%	78.9%	75.6%	0.47	0.54
	火焰	90.9%	89.2%	86.2%	84.5%	82.1%	0.61	
YOLO v8s-1	火灾	88.3%	85.9%	83.8%	82.1%	79.9%	0.46	
YOLO v8s-2	烟气	85.3%	83.5%	82.1%	79.5%	76.8%	0.45	0.52
	火焰	91.2%	89.9%	87.5%	85.1%	82.9%	0.59	

独立性指标值(IND)越小,代表该算法的探测结果受到这一探测条件的影响越小,如果 $IND>1$,则可认为该算法不适用于这一探测条件变化较大的环境,探测性能稳定性较差。对于“一2”类算法,探测火灾的独立性指标(IND)以算法探测烟气和火焰的独立性指标值的算术平均数计。

分析发现,算法的平均精度基本随着图像复杂度的增加而减小,呈单调递减关系。通过比较IND能够更直观地发现,基于YOLO v8s、YOLO v3和Faster-RCNN网络架构的算法的IND均小于1,说明其探测平均精度受图像复杂度的影响较小,在各种复杂场景下依然能保持一定的探测水平。基于SSD网络架构的算法IND值均大于1,说明其受探测难度影响较大,只适用于简单场景的火灾探测。

通过以上研究发现,评估算法在不同图像复杂度条件下的性能,并深入分析算法性能受复杂度变化的

影响程度,能够更全面了解算法在真实环境中的表现。

6 结 论

1)提出基于图像复杂度的火灾探测难易度度量方法,通过程序测试法收集人类判断图像中是否存在火灾的时间(即人类响应时间),并以此界定数据集中图像复杂度的真实值。

2)开发基于卷积神经网络的全图综合复杂度评估器,利用 Inception ResNet-v2 模型构建复杂度预测框架,实现对图像复杂度的自动预测。试验结果表明,该评估器能够对 85% 以上的图像复杂度进行正确排序,证明其为有效的复杂度度量工具。

3)提出基于图像复杂度的火灾探测算法性能评估方法,通过评估不同复杂度条件下火灾探测算法的探测性能,验证了该方法相较于传统的评估方法和仅扩充数据集的评估方法,能够更准确地评估探测算法在不同火灾探测难度条件下所能达到的探测水平,进而更准确衡量算法在实际应用中的表现,评估结论对于工程实践具有重要的指导意义。

参考文献:

- [1] GB 15631—2008, 特种火灾探测器[S].
- [2] ISO/DIS 7240-29:2024, Fire detection and alarm systems—Part 29: Video fire detectors[S].
- [3] ULC/ORD-C529A-13: 2013, Video image smoke detection system devices[S].
- [4] MUHAMMAD K, AHMAD J, MEHMOOD I, et al. Convolutional neural networks based fire detection in surveillance videos[J]. IEEE Access, 2018, 6: 18174—18183.
- [5] ÇELİK T, DEMIREL H. Fire detection in video sequences using a generic color model[J]. Fire Safety Journal, 2009, 44(2): 147—158.
- [6] CHEN T H, WU P H, CHIOU Y C. An early fire-detection method based on image processing[C]//2004 International Conference on Image Processing, 2004. ICIP '04, 2004: 1707—1710.
- [7] RONG J Z, ZHOU D C, YAO W, et al. Fire flame detection based on GICA and target tracking[J]. Optics & Laser Technology, 2013, 47: 283—291.
- [8] 严云洋, 吴茜茜, 杜静, 等. 基于色彩和闪频特征的视频火焰检测[J]. 计算机科学与探索, 2014, 8(10): 1271—1279.
- [9] 张苗, 李璞, 杨漪, 等. 基于目标检测卷积神经网络的图像型火灾探测算法[J]. 消防科学与技术, 2022, 41(6): 807—811.
- [10] 马强, 蒋弘瑞, 王可, 等. 古建筑群室外图像型火灾探测器布置优化研究[J]. 清华大学学报(自然科学版), 2025, 65(4): 625—633.
- [11] 李海, 孙鹏. 基于知识图谱的火灾图像识别研究[J]. 中国安全科学学报, 2023, 33(10): 147—159.
- [12] 张曦, 李泊宁, 李晓旭, 等. 基于颜色自注意力引导的火灾检测算法[J]. 火灾科学, 2025, 34(1): 51—56.
- [13] MARIO I, CHACON M, ALMA D, et al. Image complexity measure: A human criterion free approach[C]//NAFIPS 2005 — 2005 Annual Meeting of the North American Fuzzy Information Processing Society, 2005: 241—246.
- [14] IONESCU R T, ALEXE B, LEORDEANU M, et al. How hard can it be? Estimating the difficulty of visual search in an image[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2157—2166.
- [15] 李璞, 张苗, 杨漪. 大型火灾图像数据集的设计及建立[J]. 消防科学与技术, 2022, 41(10): 1430—1434, 1476.
- [16] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. CoRR, 2014, abs/1409.1556.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770—778.
- [18] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 2818—2826.
- [19] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]//AAAI Conference on Artificial Intelligence. Phoenix, 2016.
- [20] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 1800—1807.
- [21] HOWARD A, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv 1704.04861, 2017.
- [22] Hoeffding W, Kendall M G. Rank correlation methods[J]. Econometrica, 1957, 25(1): 181.

(责任编辑:毛 星)