

文章编号: 2095-4980(2021)03-0458-07

## 基于熵值加权支持向量机的火焰检测方法

王彦朋, 柴文\*, 王晓君

(河北科技大学 信息科学与工程学院, 河北 石家庄 050000)

**摘要:** 提出一种基于熵值加权支持向量机(SVM)的火焰检测方法。采用三帧差分算法对视频前景提取(VIBE)算法进行改进, 并提出TH-VIBE前景检测算法, 提升疑似火焰区域获取的准确率与完整性; 利用熵值加权降低纹理特征、面积变化特征、圆形度特征、灰度特征等特征数据的冗余程度并建立熵值加权火焰识别模型, 提升火焰识别速率与准确率; 最后依据韩国启明大学和土耳其比尔肯大学SPG工作组火焰数据进行实验, 火焰检测准确率可达97%, 具有较高的鲁棒性。

**关键词:** 火焰检测; TH-VIBE 算法; 熵值加权支持向量机; 多特征融合

中图分类号: TN911.73

文献标志码: A

doi: 10.11805/TKYDA2020210

## Flame detection method based on entropy weighted Support Vector Machine

WANG Yanpeng, CHAI Wen\*, WANG Xiaojun

(School of Information Science and Engineering, Hebei University of Science and Technology, Shijiazhuang Hebei 050000, China)

**Abstract:** A flame detection method based on entropy weighted Support Vector Machine(SVM) is proposed. Firstly, the three-frame difference algorithm is utilized to improve the Visual Background Extractor(VIBE) algorithm, and the Three VIBE(TH-VIBE) foreground detection algorithm is proposed to improve the accuracy and integrity of the acquisition of the suspected flame area. Secondly, entropy weighting is adopted to reduce the redundancy degree of feature data such as texture feature, area change feature, roundness feature and gray level feature, and an entropy-weighted flame recognition model is established to improve the flame recognition rate and accuracy. Finally, based on the flame data from Keimyung University in South Korea and SPG working group of Bilkent University in Turkey, the flame detection accuracy can reach 97% with high robustness.

**Keywords:** flame detection; TH-VIBE algorithm; entropy weighted Support Vector Machine; multi-feature fusion

近年来, 火灾事故时有发生, 火灾的发生不仅会带来严重的经济损失, 还会造成一定数量的人员伤亡, 因此对火灾的早期火焰进行识别与报警显得尤为重要。目前, 国内外已有众多学者在视频火灾检测领域进行了深入研究。严云洋等<sup>[1]</sup>利用火焰图像序列的边缘特性、颜色面积等特征进行视频火灾识别, 较好地提升了识别速度, 但鲁棒性不高; 王琳等<sup>[2]</sup>利用帧间差分算法提取运动前景, 将火焰的动态、静态特征输入 AdaBoost 分类器进行是否起火判断, 但抗干扰能力低下; 钟中志等<sup>[3]</sup>利用颜色空间、高斯模型与支持向量机实现视频图像的火焰识别, 但对光照变化的鲁棒性不足。

本文通过对火焰特征的深入研究, 利用三帧差分算法对传统 VIBE 算法进行优化, 提出 TH-VIBE 算法获取疑似火焰区域, 同时结合熵值支持向量机建立火焰识别模型, 提升火焰识别率。TH-VIBE 算法依据火灾火焰的运动特征, 将三帧差分结果作为 VIBE 算法的背景更新依据, 使疑似火焰区域更加完整, 同时有效抑制“鬼影”的产生; 然后对疑似火焰区域所提取的特征向量进行熵值加权, 获得加权特征向量; 最后将加权后的特征向量输入分类器进行火焰识别。该算法将火焰特征的动态与静态有效结合, 依据权值对特征向量进行重要性判定, 有效提升识别模型的检测性能。

收稿日期: 2020-05-15; 修回日期: 2020-07-07

基金项目: 河北科技大学五大平台开发基金课题资助项目(2018PT13)

作者简介: 王彦朋(1969-), 男, 教授, 主要研究方向为电子信息处理。email:284625449@qq.com

\*通信作者: 柴文 email:1761332559@qq.com

### 1 TH-VIBE 算法获取疑似火焰区域

采用 VIBE 算法提取火焰区域,“鬼影”与火焰形状不完整等问题无法避免。本文根据火焰图像的高亮度、易受干扰的特性<sup>[4]</sup>,对 VIBE 算法进行改进,提出 TH-VIBE 算法。将三帧差分算法处理结果作为 VIBE 算法前景判断和背景更新的参考范围。TH-VIBE 算法处理结果与根据亮度阈值二值图像进行逻辑“与”运算,获得高亮度运动区域。通过实验验证,该方法克服了传统 VIBE 算法“鬼影”与火焰形状残缺的不足,准确地提取出火焰目标区域。算法原理如图 1 所示。

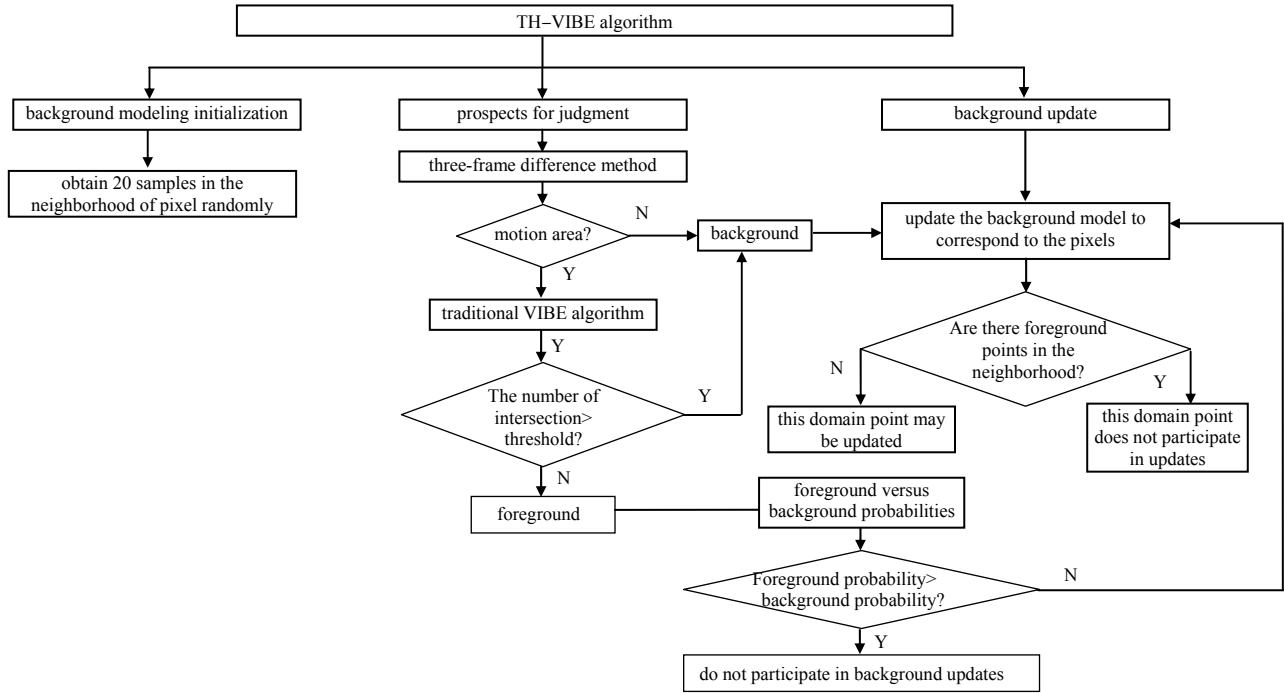


Fig.1 Principle of TH-VIBE algorithm  
图 1 TH-VIBE 算法原理

#### 1.1 基于三帧差分法的图像分割

在提取运动目标之前,首先对视频序列进行预处理。图像去噪和降维操作可以减少噪声干扰和计算量<sup>[5]</sup>。运用三帧差分算法获得背景更新以及前景判断像素点范围依据的同时,合理利用三帧差分法对光强不敏感的优势,有效解决了传统 VIBE 算法对光强动态变化敏感的缺点。

设  $p(x,y,t-1)$ ,  $p(x,y,t)$ ,  $p(x,y,t+1)$  为视频的 3 个时序相邻帧,进行三帧差分运算得到差分图像  $D(x,y,\Delta t)$  为:

$$D(x,y,\Delta t) = |p(x,y,t) - p(x,y,t-1)| \cap |p(x,y,t+1) - p(x,y,t)| \quad (1)$$

设置阈值  $\tau$  对图像进行分割,分割后的二值图像  $R(x,y)$  为:

$$R(x,y) = \begin{cases} 1, D(x,y,\Delta t) \geq \tau \\ 0, D(x,y,\Delta t) < \tau \end{cases} \quad (2)$$

#### 1.2 TH-VIBE 算法

##### 1.2.1 背景模型初始化

以首帧图像内所有像素点建立背景模型  $M(x)$ ,采用随机策略,从像素点  $x$  周围 8 邻域内选取 20 个样本值,使像素点  $v(x)$  邻域像素点被选中的概率相同,确保像素点背景模型的可参考性与真实性。

##### 1.2.2 前景获取

VIBE 算法对图像内所有像素点进行前景判断,运算效率低下。TH-VIBE 算法仅对三帧差分算法获取到的前景像素点进行二次前景提取,因此算法判别范围急剧缩小,有效提升了算法效率。以三帧差分前景像素点  $v(x)$  为圆心,  $R$  为半径建立二维欧式距离空间  $S_R(v(x))$ ,若  $S_R(v(x))$  与  $M(x)$  交集大于阈值  $C$ ,则  $v(x)$  为背景;反之,为前景。分类原理如图 2 所示。




Fig.2 Pixel classification principle in two-dimensional space  
图 2 二维空间像素分类原理

### 1.2.3 背景更新

VIBE 算法在背景更新时采用自身像素与邻域像素同步更新策略, 极易造成火焰像素点丢失。TH-VIBE 算法对前景像素点与背景像素点采取不同的更新方式。当此像素点被判别为背景像素时, 对其背景模型对应的像素点进行更新。对其邻域像素点更新时, 需进行是否包含前景像素点判断, 若某邻域像素点为前景像素点, 则放弃对其进行更新。针对前景像素点, 引入背景计数器与前景计数器。若此像素点在后续帧中被判别为前景或背景, 其对应计数器进行计数, 累加到一定程度进行概率比较。若前景概率较大, 则此区域不被更新到背景中; 反之, 则更新到背景中。

### 1.3 获取疑似火焰区域

利用 TH-VIBE 算法获取的粗运动目标中仍存在大量干扰物。根据文献[6]得知, 火焰的灰度值最低为 180, 因此本文将图片二值化阈值设置为 190, 获得高亮度图像区域, 排除大量低亮度干扰。将粗运动目标与亮度分割结果进行“与”运算, 获得高亮度运动区域。最后对高亮运动区域进行形态学处理。

## 2 熵值加权支持向量机火焰识别算法

首先利用 TH-VIBE 算法获取疑似火焰区域, 然后在此区域提取火焰特征, 依据特征向量离散度进行向量加权, 将加权特征输入分类器, 获得判断结果。视频火焰的检测算法流程如图 3 所示。TH-VIBE 算法获取到完整的疑似火焰区域, 在此基础上进行特征提取更具有真实性与有效性。相较于火焰的颜色、阶跃率等特征, 火焰的纹理特征、灰度特征、面积变化率、圆形度特征更加稳定, 且人为干扰小。因为颜色、阶跃率等特征研究中常用到阈值分析, 阈值的设定有一定的经验规律性, 会影响对火焰特征的客观描述。除此之外, 熵值加权支持向量机将各特征向量的数据达到最大使用率, 根据各特征分量的重要性分析, 合理分配比重, 更加客观地描述出火焰识别过程。

### 2.1 特征向量提取

#### 2.1.1 纹理特征

灰度共生矩阵理论以图像的二阶概率密度函数为基础, 对图像中相关像素的分布规律进行描述。该理论在灰度共生矩阵的基础上进行能量、熵、惯性矩、相关性等的计算, 大多选择从  $0^\circ, 45^\circ, 90^\circ, 135^\circ$  4 个角度进行纹理分析。共生矩阵表示为  $P_{(i,j)}(i, j=0, 1, \dots, L-1)$ , 其中  $L$  为图像灰度级,  $(i, j)$  为像素的灰度<sup>[7]</sup>。

能量值  $E$ : 与图像细腻程度相关, 纹理越细腻, 则能量越小; 反之, 越大。

$$E = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_{(i,j)}^2 \quad (3)$$

惯性矩  $C$ : 与纹理深度相关, 惯性矩越大, 纹理越清晰。

$$C = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i-j)^2 P_{(i,j)} \quad (4)$$

熵(entropy): 表达纹理的复杂程度, 复杂程度越高, 则熵越大。

$$ENT = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P_{(i,j)} \lg P_{(i,j)} \quad (5)$$

相关性(correlation): 表达矩阵元素均匀程度, 纹理分布越均匀, 则相关性越大。

$$COR = \frac{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [ijP_{(i,j)}] - \mu_1 \mu_2}{\sigma_1^2 \sigma_2^2} \quad (6)$$

式中:  $\mu_1 = \sum_{i=0}^{L-1} i \sum_{j=0}^{L-1} P_{(i,j)}$ ;  $\mu_2 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} j P_{(i,j)}$ ;  $\sigma_1^2 = \sum_{i=0}^{L-1} (i-\mu_1)^2 \sum_{j=0}^{L-1} P_{(i,j)}$ ;  $\sigma_2^2 = \sum_{j=0}^{L-1} (j-\mu_2)^2 \sum_{i=0}^{L-1} P_{(i,j)}$ 。

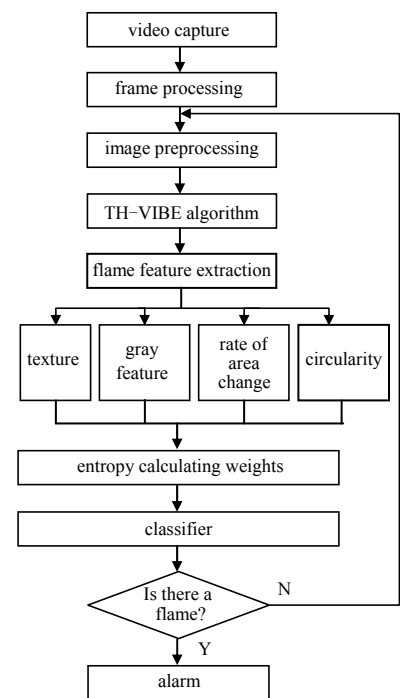


Fig.3 Flow chart of detection algorithm  
图 3 检测算法流程图

### 2.1.2 灰度特征

火焰的不断闪烁,在图像处理中体现为灰度值的不断改变,因此在火焰识别中图像总体灰度均值与标准差可作为2个有效的特征向量。灰度均值  $M$  表示图像灰度的平均水平,标准差  $ST$  则表示图像中灰度的波动起伏。 $G(i,j)$  表示坐标  $(i,j)$  处的灰度值,  $m \times n$  表示总像素个数。

$$M = \frac{\sum_{i=1, j=1}^{i=m, j=n} G(i, j)}{m \times n} \quad (7)$$

$$ST = \sqrt{\sum_{i=1, j=1}^{i=m, j=n} (G(i, j) - M)^2} \quad (8)$$

### 2.1.3 疑似火焰面积变化率

火焰面积具有连续的、不断变化的特征。在图像中,疑似火焰面积占有率也在不断发生变化,因此火焰区域面积变化率可以作为火焰特征向量之一。计算公式如下:

$$A_{\Delta t} = \frac{S_{k+t} - S_k}{t} \quad (9)$$

式中:  $A_{\Delta t}$  为  $t$  时间段内的面积变化率;  $S_{k+t}$  为第  $k+t$  帧图像中疑似火焰面积;  $S_k$  为第  $k$  帧图像中疑似火焰面积。

### 2.1.4 圆形度特征

圆形度是一个表征物体形状复杂度的概念<sup>[8]</sup>。相较闪烁的霓虹灯、灯光等外形稳定的干扰物,火焰的形状复杂程度与其存在明显的差别,因此可将圆形度作为火焰判断依据之一。圆形度的计算公式为:

$$C_k = \frac{P_k^2}{4\pi A_k} \quad (k = 1, 2, \dots, n) \quad (10)$$

式中:  $C_k$  为第  $k$  帧图像中疑似火焰区域的圆形度;  $P_k$  为疑似火焰区域的周长;  $A_k$  为疑似火焰区域的面积;  $n$  为数据集总量。

## 2.2 特征向量熵值加权与识别

SVM 分类理论最早由 Vapnik 等提出,现已发展为比较成熟的理论<sup>[9]</sup>,广泛用于火灾检测等领域。SVM 相对比深度学习等其他机器学习方法,避免了局部最优解、过拟合以及“维数灾难”等问题<sup>[10]</sup>,其最显著优势在于训练样本小且训练维度高,在实际应用中表现十分突出。

熵值支持向量机训练样本的核心思路是把熵值加权后的向量组经过非线性变换映射到高维核空间,在此空间寻求最优分类平面,使两类间隔最大。非线性变换主要依靠核函数完成,此外,建模过程中最重要的是特征向量的建立。SVM 建模过程中,各个特征其离散度与重要性并不相同。为防止特征向量数据的冗余以及低影响值数据对训练结果的影响,对特征向量组进行熵值权重分析。将特征向量组成特征向量组进行归一化操作和其对应熵值的计算,最终将完成重要性评估的特征向量输入 SVM 模型中进行火焰检测。

火焰的四类共 8 种特征  $m$  维数据  $\mathbf{X}$  表示为:

$$\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1m} \\ x_{21} & \cdots & x_{2m} \\ x_{31} & \cdots & x_{3m} \\ \vdots & \vdots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{bmatrix} \quad (11)$$

式中:  $m=8$ , 代表 8 种特征;  $n$  为样本连续帧数组总和。

对于多维特征向量,首先对输入数据做预处理,消除量纲,避免各个特征之间的量级差异<sup>[11]</sup>。

计算各特征量权重步骤如下:

1) 计算特征向量数据占有率:

$$f_{ik} = \frac{x_{ik}}{\sum_{i=1}^n x_{ik}} \quad (k = 1, 2, \dots, m) \quad (12)$$

式中:  $i$  表示第  $i$  张图;  $x_{ik}$  为第  $k$  种特征的第  $i$  个特征量的数值;  $f_{ik}$  为第  $k$  种特征的第  $i$  个特征量所占比重。

得到占有率矩阵  $\mathbf{F}$ :

$$\mathbf{F} = \begin{bmatrix} f_1 \\ f_2 \\ f_3 \\ \vdots \\ f_n \end{bmatrix} = \begin{bmatrix} f_{11} & \cdots & f_{1m} \\ f_{21} & \cdots & f_{2m} \\ f_{31} & \cdots & f_{3m} \\ \vdots & \vdots & \vdots \\ f_{n1} & \cdots & f_{nm} \end{bmatrix} \quad (13)$$

2) 计算各特征向量对应熵值:

$$E_k = -K \sum_{i=1}^n f_{ik} \ln f_{ik} \quad (14)$$

式中:  $E_k$  为所有特征输入量对第  $k$  项指标的贡献总量; 常数  $K=1/\ln(n)$ 。若熵值  $E_k$  为 1, 则该指标无参考价值, 可不将其考虑在特征值影响因素内。

3) 计算各特征量权值: 利用得到的熵值, 进行特征向量输入参数的一致性评估。

$$D_k = 1 - E_k \quad (15)$$

$D_k$  值表示第  $k$  维特征信息参数的一致性,  $D_k$  越小, 则权重越小。各维参数的权重  $\omega_k$  为:

$$\omega_k = \frac{D_k}{\sum_{k=1}^m D_k} (k = 1, 2, \dots, m) \quad (16)$$

将归一化之后的数据与求出的特征权重进行相乘, 即为所需输入的最终的数据向量  $\mathbf{Y}_{ik}$ 。

$$\mathbf{Y}_{ik} = t_{ik} \times \omega_k (i = 1, 2, \dots, n; k = 1, 2, \dots, m) \quad (17)$$

式中  $t_{ik}$  为归一化之后的特征量。

### 3 实验结果与分析

#### 3.1 实验样本介绍

实验所用数据部分来源于韩国启明大学计算机视觉与模式识别实验室和土耳其比尔肯大学 SPG 工作组, 部分来源于网络。实验数据描述如表 1 所述, 部分火焰视频和非火焰视频图像如图 4 所示。

实验共包含 7 类不同形态的火焰视频和 3 类非火焰视频。基于动静态特征的综合考虑, 需进行连续图像帧的提取。从以上 10 个视频中, 共提取火焰序列 1 600 帧, 非火焰序列 570 帧。为减小随机因素影响, 选择连续 10 帧图片进行一次特征提取, 其中, 动态特征以第  $k$  帧图像所提取的特征值为参考, 与第  $k+9$  张图进行变化量均值计算的方式进行提取; 静态特征则将本数据组的最后一张图的特征定义为本组数据的静态特征。

通过计算共得到特征向量样本 264 组, 其中正样本特征向量 160 组, 负样本特征向量 104 组。正特征向量的标签为 1, 负特征向量的标签为 0。训练集比例为 70%, 测试集比例为 30%。

表 1 实验样本视频描述

Table 1 Video description of experimental samples

| video number | video description                         | frame number | interference factor                          |
|--------------|---|--------------|--|
| 1            | 10 meters burning outside at night        | 200          | large area light and shadow                  |
| 2            | 20 m burning outdoors at night            | 200          | distance and large areas of light and shadow |
| 3            | 10 meters burning outdoors during the day | 300          | people walking back and forth                |
| 4            | 20 m indoor combustion at night           | 300          | high brightness light and shadow             |
| 5            | field weed burning                        | 200          | red land                                     |
| 6            | small room burning                        | 200          | flashlight                                   |
| 7            | hill fire                                 | 200          | dry trees and weeds                          |
| 8            | a moving man in red                       | 170          | similar to the color of flame                |
| 9            | flashing neon lights                      | 470          | continuous flashing feature                  |
| 10           | flashing screen                           | 400          | continuous flashing and moving features      |

#### 3.2 实验仿真结果与分析

##### 3.2.1 仿真结果

疑似火焰提取结果如图 5 所示, 图 5 第 1 行为包含火焰图像疑似火焰区域提取结果, 第 2 行为干扰图像疑似火焰提取结果。对样本视频的特征向量进行部分结果展示, 如表 2 所示。



Fig.4 Part of the video pictures

图 4 部分视频图片

表 2 火焰及干扰的特征提取结果

Table2 Feature extraction results of flame and interference

| video number | rate of area change | gray average | gray standard deviation | energy | entropy | inertia moment | correlation | circularity |
|--------------|---------------------|--------------|-------------------------|--------|---------|----------------|-------------|-------------|
| video 1      | 104.90              | 109.26       | 51.16                   | 0.08   | 3.08    | 2.59           | 0.81        | 0.22        |
| video 2      | 191.10              | 122.31       | 49.88                   | 0.09   | 3.03    | 2.63           | 0.76        | 0.37        |
| video 8      | 10.20               | 139.22       | 54.05                   | 0.04   | 3.68    | 2.06           | 0.05        | 0.91        |
| video 9      | 8.90                | 140.54       | 55.25                   | 0.05   | 4.27    | 2.11           | 0.03        | 0.87        |

由表中数据可以看出, 火焰样本与非火焰样本在 8 个特征中存在明显差异, 以上 8 个特征都可参考为有效特征, 有助于火焰识别模型的建立。

3.2.2 模型参数选择

考虑到实验数据的数量适中且特征向量维度较低, 选择高斯核函数作 SVM 分类器的核函数。和其他核函数相比, 径向基函数兼顾了计算性能和运行速度, 可以较大程度地提升支持向量机的检测能力<sup>[12]</sup>。经过交叉验证, 惩罚因子选取 100,  $\delta$  选取 0.3 效果最好。利用熵值法计算 8 种特征向量对应权值, 结果见表 3。




Fig.5 Extraction results of suspected flame area

图 5 疑似火焰区域提取结果

表 3 不同特征所对应权值

Table3 Weight values corresponding to different features

| feature | rate of area change | gray average | gray standard deviation | energy  | entropy | inertia moment | correlation | circularity |
|---------|---------------------|--------------|-------------------------|---------|---------|----------------|-------------|-------------|
| weight  | 0.141 6             | 0.178 0      | 0.187 7                 | 0.133 4 | 0.101 5 | 0.118 6        | 0.169 8     | 0.102 3     |

3.2.3 实验结果及分析

为进一步验证特征向量的选取对于模型建立的影响, 对各种特征向量构建模型的结果进行比较, 结果如图 6 所示。

本文中四类共 8 种特征, 疑似火焰面积变化率特征为  $S$ , 模型准确率为 85.3%。图像灰度变化为  $G$ , 模型准确率为 70.67%。纹理特征为  $L$ , 模型准确率为 80.68%。圆形成度  $C$  模型准确率为 79.86%, 可见单特征模型效果并不理想。将这四类特征同时作为特征向量输入到模型中, 传统 SVM 模型准确率为 90.12%, 加权 SVM(w-SVM)模型准确率为 97.68%。

为验证本文算法有效性, 选取 3 个没有参与训练的视频与参考文献[13-14]的算法进行对比实验, 结果如表 4~表 5 所示。




Fig.6 Effect comparison of feature models

图 6 特征模型效果对比

表 4 测试训练集介绍

Table4 Test training sets

| video  | number of frames | flame frames | no fire frames |
|--------|------------------|--------------|----------------|
| video1 | 708              | 696          | 12             |
| video2 | 1 201            | 1 176        | 25             |
| video3 | 140              | 82           | 58             |
| video4 | 155              | 0            | 155            |

表 5 识别结果对比

Table5 Comparison of recognition results

| video  | Ref.[13] |       |    |     |           |         |       | Ref. [14] |       |    |     |       |           |         | proposed |       |    |     |       |           |         |
|--------|----------|-------|----|-----|-----------|---------|-------|-----------|-------|----|-----|-------|-----------|---------|----------|-------|----|-----|-------|-----------|---------|
|        | FN       | TP    | FP | TN  | miss rate | FP rate | Acc   | FN        | TP    | FP | TN  | Acc   | miss rate | FP rate | FN       | TP    | FP | TN  | Acc   | miss rate | FP rate |
| video1 | 37       | 659   | 7  | 5   | 5.3%      | 1.1%    | 93.7% | 32        | 664   | 5  | 7   | 96.4% | 4.5%      | 0.7%    | 11       | 685   | 2  | 10  | 98.1% | 1.6%      | 0.3%    |
| video2 | 73       | 1 103 | 15 | 10  | 6.2%      | 1.3%    | 92.6% | 60        | 1 116 | 12 | 13  | 94.0% | 5.1%      | 1.1%    | 15       | 1 161 | 5  | 20  | 98.3% | 1.3%      | 0.4%    |
| video3 | 7        | 75    | 1  | 57  | 8.5%      | 1.3%    | 94.2% | 5         | 77    | 3  | 55  | 94.2% | 6.1%      | 3.8%    | 2        | 80    | 2  | 56  | 95.7% | 2.4%      | 2.4%    |
| video4 | 0        | 0     | 3  | 152 | 1.9%      | null    | 98.0% | 0         | 0     | 6  | 149 | 96.1% | 3.8%      | null    | 0        | 0     | 5  | 150 | 96.7% | 3.2%      | null    |

表中 FN 代表火焰视频漏检帧数, TP 代表火焰视频的正确检测帧数, FP 代表非火焰视频误检帧数, TN 代表非火焰图片的正确检测帧数, Missrate 代表漏检率, FPrate 代表虚警率, Acc 代表准确率。Video1 为杂草燃烧视频, Video2 为红色田地杂物燃烧视频, 都存在背景干扰, Video3 为白天远距离火焰视频, Video4 为夜晚车灯视频。经过测试, 本文算法的漏检率为 2.12%, 虚警率为 1.0%, 平均准确率为 97.24%。文献[13]检测算法漏检率

为 5.48%，虚警率为 1.23%，平均准确率 94.69%。文献[14]检测算法漏检率为 4.87%，虚警率为 1.43%，平均准确率 95.20%。综上，本文提出的多特征熵值支持向量机火焰分类算法，明显优于单特征分类器算法，同时相较于文献[13-14]的算法具有更高的准确率、较低的漏检率与虚警率。

#### 4 结论

本文首先利用三帧差分算法对 VIBE 算法进行改进，提出 TH-VIBE 算法。在疑似火焰区域提取方面与现有算法相比较，提高了前景检测的准确性，同时提升了应对环境光照变化方面的鲁棒性，为后期特征提取奠定了很好的基础。其次，经过试验验证，本文基于熵值算法的加权支持向量机的火焰识别方法，有效降低了数据的冗余程度，提升了识别准确率。但在真实的火灾环境中，还存在大量繁杂的干扰，因此算法的抗干扰性与稳定性将会是后期研究的重要目标。

#### 参考文献：

- [1] 严云洋,高尚兵,郭志波,等. 基于视频图像的火灾自动检测[J]. 计算机应用研究, 2008,25(4):1075-1078. (YAN Yunyang, GAO Shangbing, GUO Zhibo, et al. Implementation of automatic fire detection in video sequences[J]. Computer Application Research, 2008,25(4):1075-1078.)
- [2] 王琳,姚新,雷丹. 公路隧道火灾初期视频火焰检测[J]. 中国公路学报, 2018,31(11):121-129. (WANG Lin, YAO Xin, LEI Dan. Video flame detection in early stage of highway tunnel fire[J]. Chinese Journal of Highway and Transport, 2018, 31(11):121-129.)
- [3] 钟中志. 面向视频图像的火焰识别算法研究[D]. 合肥:安徽大学, 2019. (ZHONG Zhongzhi. Research on flame recognition algorithm for video image[D]. Hefei, Anhui, China: Anhui University, 2019.)
- [4] 杨柳,张德,王亚慧,等. 城市火灾视频监控目标区域图像准确检测仿真[J]. 计算机仿真, 2019,36(4):425-431. (YANG Liu, ZHANG De, WANG Yahui, et al. Simulation of accurate detection of target area image in urban fire video surveillance[J]. Computer Simulation, 2019,36(4):425-431.)
- [5] YUANBIN W, JIEYING R. An improved VIBE based on Gaussian pyramid[C]// International Conference on Control and Robotics Engineering (ICCRE). Nanjing, China: [s.n.], 2019.
- [6] 徐博. 基于视频的真实场景火焰检测[D]. 沈阳:辽宁科技大学, 2016. (XU Bo. Real scene flame detection based on video[D]. Shenyang, China: Liaoning University of Science and Technology, 2016.)
- [7] 单慧勇,曹燕,赵辉,等. 二维相关红外光谱与支持向量机和灰度共生矩阵统计法相结合判别掺杂牛奶[J]. 理化检验(化学分册), 2019,55(3):254-259. (SHAN Huiyong, CAO Yan, ZHAO Hui, et al. Identification of adulterated milk by 2D correlation infrared spectroscopy in combination with support vector machine and gray co-occurrence matrix statistical method[J]. Physical Testing and Chemical Analysis Part B: Chemical Analysis, 2019,55(3):254-259.)
- [8] 朱思思,丁德红,陈朝迎,等. 基于图像处理的森林火灾识别方法研究[J]. 红外技术, 2016,38(5):440-446. (ZHU Sisi, DING Dehong, CHEN Chaoying, et al. Research on forest fire identification method based on image processing[J]. Infrared Technology, 2016,38(5):440-446.)
- [9] 盖超会,王成刚. 基于改进布谷鸟算法与 SVM 的矿用变压器故障诊断[J]. 煤炭工程, 2019,51(11):134-137. (GAI Chaohui, WANG Chenggang. Fault diagnosis of mine transformer based on improved cuckoo algorithm and SVM[J]. Coal Engineering, 2019,51(11):134-137.)
- [10] 陈焱,宋召青. 基于复合核支持向量回归机的多类分类算法[J]. 太赫兹科学与电子信息学报, 2017,15(6):1039-1044. (CHEN Yao, SONG Zhaoqing. Multi-class classification method based on support vector regression machine with composite kernel function[J]. Journal of Terahertz Science and Electronic Information Technology, 2017,15(6):1039-1044.)
- [11] 刘畅,范彬. 基于熵值法的加权最小二乘支持向量机[J]. 计算机科学, 2017,44(S2):428-431. (LIU Chang, FAN Bin. A weighted least squares support vector machine based on entropy method[J]. Computer Science, 2017,44(S2):428-431.)
- [12] HSU C W, CHANG C C, LIN C J. A practical guide to Support Vector Classification[D]. Taipei, Taiwan, China: National Taiwan University, 2016.
- [13] WANG X, LI Y, LI Z. Research on flame detection algorithm based on multi-feature fusion[C]// 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Chongqing, China: IEEE, 2020:184-189.
- [14] 徐雪燕. 基于视频处理的火焰和烟气检测方法研究[D]. 武汉:武汉理工大学, 2016. (XU Xueyan. Research on flame and smoke detection method based on video processing[D]. Wuhan, Hubei, China: Wuhan University of Technology, 2016.)