

用两层分类算法进行视频烟雾检测

仝伯兵 王士同

(江南大学数字媒体学院 无锡 214122)

摘要 为提高视频烟雾检测的准确性,提出一种基于概率的两层最近邻自适应度量分类算法(PTLNN)来进行烟雾检测。该算法以最小化平均绝对误差为原则,结合 AdaBoost 和 KNN 算法的优势,充分考虑局部和全局的样本分布,能明显提升分类精度。采用离散余弦变换(DCT)和离散小波变换(DWT)两种方式对烟雾特征进行提取,并验证算法性能。通过与传统算法的对比实验发现,采用离散余弦变换并结合 PTLNN 算法在视频烟雾检测方面具有更好的效果,既满足实时性要求又提高了检测精度。

关键词 两层分类,平均绝对误差,基于概率,烟雾检测,离散余弦变换

中图分类号 TP391.41 文献标识码 A DOI 10.11896/j.issn.1002-137X.2015.3.062

Video Smoke Detection Using Two-level Classification Algorithm

TONG Bo-bing WANG Shi-tong

(School of Digital Media, Jiangnan University, Wuxi 214122, China)

Abstract In order to improve the accuracy of video smoke detection, a probability-based two-level nearest neighbor classification algorithm (PTLNN) was proposed to detect smoke in video. Aiming at minimizing the mean absolute error of principle, combining the advantages of AdaBoost and KNN algorithm, and fully considering local and global sample distribution, the proposed algorithm can significantly improve the classification accuracy. The proposed algorithm adopts the discrete cosine transform (DCT) and discrete wavelet transform (DWT) two ways to extract smoke characteristics. By comparing with the traditional algorithms, the proposed PTLNN algorithm with the discrete cosine transform has better effectiveness on video smoke detection which not only meets the real-time requirements but also improves the detection accuracy.

Keywords Two-level classification, Mean absolute error, Probability-based, Smoke detection, Discrete cosine transform

1 引言

火灾严重威胁人类的生命和财产安全,因此及时检测和预防火灾具有重要意义^[1]。目前,较成熟的火灾检测方法有感烟、感温、感光等探测技术。这些基于传感器的探测技术要求探测器必须安装在起火点附近,且检测依据单一,容易受监控环境的面积、温度和气流等因素的影响。因此,传统火灾探测器的应用范围受到很大的限制。

随着视频监控技术和无线宽带信号传输技术的发展,人们开始致力于基于视频图像的火灾探测研究^[2-5]。通过分析火灾的颜色、运动信息及状态等进行综合判断以确定是否有火灾发生。在火灾监控中,烟雾检测对于实现早期的火灾预警具有重要意义。相比于火焰,烟雾的颜色、梯度等信息表现得更不明显,因此,良好的特征是实现烟雾检测的关键。其中文献[6,7]使用色调、亮度等颜色特征建立模型进行烟雾检测。文献[8]提出了火灾烟气移动方向角累计模型,通过该模型获取方向角直方图从而实现对烟气的识别。文献[9]则根据烟气密度分布的变化及轮廓变化的不规则性进行建模,通

过支持向量机设计分类器进行识别。在文献[10]中,利用烟雾自身光学动态特征(如光流方向性、相关性等特征)对烟雾可疑区域进行标志,再经数据融合算法来有效区分森林烟雾与大气云雾。文献[11]提出了一种采用小波变换算法进行分析与支持向量机(SVM)相结合的检测方法;Wang^[12]用 Ada-boost 直接对小波系数进行分类但不进行降维处理,在准确度上具有良好的效果。我们的方式与此类似,本文提出一种基于概率的两层最近邻自适应度量分类算法(PTLNN)进行烟雾检测。该算法以最小化平均绝对误差为原则,结合 Ada-Boost 和 KNN 算法的优势,充分考虑局部和全局的样本分布,能明显提升分类精度。采用离散余弦变换(DCT)和离散小波变换(DWT)两种方式对烟雾特征进行提取,并验证检测效果。

本文第2节介绍视频图像的处理及特征提取,并提出算法;第3节给出算法的实验结果与分析;最后给出结论。

2 方法

烟雾检测主要思路是用高效的特征对图像进行描述,用

到稿日期:2014-04-01 返修日期:2014-08-13 本文受国家自然科学基金项目(61170122,61272210)资助。

仝伯兵(1989—),男,硕士生,主要研究方向为人工智能与模式识别、数字图像处理,E-mail: tongbobing@163.com;王士同(1964—),男,教授,主要研究方向为人工智能、模式识别、生物信息。

合适的高效分类器进行块处理来检测烟雾。本文将每一帧图像分成固定像素的小块,检测每块是否有烟雾存在。模式识别方法的基本架构包括预处理、特征提取和分类子单元训练和测试阶段。

2.1 数据预处理

我们将所有视频的数据图像进行灰度处理,由于所有视频分辨率均为 240×320 ,每一帧图像分为 60×60 像素的小块,因此图像被分为 3×4 块,处理结果如图 1 所示。从图 1 可以看出图像中有明显的烟雾存在,我们将图像分块并对图像中的每块进行分别检测,所有块中有烟雾的标记为正,其余标记为负。



图 1 分块样例

2.2 特征提取

图像特征提取是指将图像像素中一些鲜明的特性进行提取利用。我们用基于概率的两层最近邻自适应度量分类算法并采用离散余弦变换(DCT)和离散小波变换(DWT)之后产生的特征分别进行烟雾检测。

2.2.1 离散余弦变换(DCT)

离散余弦变换(DCT)将图像信号从空间域变换到 DCT 变换域,保持原始信号的熵和能量不变,然后再对 DCT 变换域系数进行量化和编码。二维离散余弦变换为:

$$C(u, v) = a(u) a(v) \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cos \left[\frac{\pi(2x+1)u}{2N} \right] \cdot \cos \left[\frac{\pi(2y+1)v}{2N} \right] \quad (1)$$

其中:

$$a(u), a(v) = \begin{cases} \sqrt{\frac{1}{N}}, & \text{当 } u, v = 0 \text{ 时} \\ \sqrt{\frac{2}{N}}, & \text{当 } u, v \neq 0 \text{ 时} \end{cases} \quad (2)$$

离散余弦变换中低频组件代表一般形状而高频组件代表图像的边缘和细节。低频组件向左上角的块转换数据,高频组件向右下方的块转换数据。我们以 Video2 视频第 6 帧和第 90 帧为例(见图 2),经过离散余弦变换(DCT)后以能量图方式(见图 3)表示,可以发现图像的能量都集中在了左上角,而且在出现烟雾后图像能量降低。在特征提取时,由于低频数据存储该对象的最大信息,我们将每个对象离散余弦变换后集中于左上角的 64 个图像系数作为烟雾检测的特征向量。



图 2 第 6 帧和第 90 帧图像




图 3 第 6 帧和第 90 帧图像 DCT 能量图

2.2.2 离散小波变换(DWT)

小波是将数据分解成不同的频率成分来研究每个组件与其规模分辨率匹配的数学函数。小波变换可以表示为一组基函数的线性组合,连续小波变换可以表示为:

$$f(a, b) = \frac{1}{\sqrt{a}} \int f(t) \Psi^* \left(\frac{t-b}{a} \right) dt \quad (3)$$

离散小波变换(DWT)是基于自带编码,小波变换是通过离散时域信号连续的低通和高通的滤波分解:

$$C^k = [A_k, (H_1, V_1, D_1), \dots, (H_k, V_k, D_k)] \quad (4)$$

其中, A_k 是图像 k 层分解的低频近似系数, (H_i, V_i, D_i) 是图像在 i 层频率分解,通过高通滤波器在 3 个方向(水平、垂直和对角)获得的详细信息,图 4 显示的是一个 3 层分解。 k 层小波变换将原始图像用 $3k+1$ 个子图像表示,这种多分辨率的分析使我们能够分析信号不同频带,从而提供信息中的任何瞬态时域以及频域。




图 4 离散小波变换 3 层分解图

利用小波变换进行图像分析近年来得到广泛应用^[13],用此种方法来表征烟雾也是非常有效的。图 4 所示为每层变换后的子图像包含在水平、垂直和对角线方向的信息。如果将所有这些系数作为特征处理是非常耗时的。为提高效率,我们用推导出的 6 个特征来表示子图像。这 6 个特征是算术平均数、几何平均数、标准差、偏度、峰度和熵。在正常(非烟)的图像中,这些特征遵循一定的模式与烟雾图像不同。图 5 所示为 Video 2 视频第 6 帧和第 90 帧图像经过第一层小波分解后,低频系数数据分布的偏度(为使特征明显,此处我们以第一层小波分解低频系数为例)。然而一个特征不足以充分区分烟雾的存在,因此图 4 中所示的每个子块都将计算这 6 个特征,共产生 60 个特征作为分类器的输入。




图 5 第 6 帧和第 90 帧图像第一层 DCT 低频数据分布偏度

2.3 基于概率的两层自适应度量算法(PTLNN)

由于烟雾受环境影响巨大,在干扰的情况下很难准确地进行烟雾检测,因此有必要对已有的算法进行改进。文献[14]提出了一种基于自适应距离度量的两层最近邻分类算法,该算法以最优训练样本分类错误率的最小平方差为目标,然而该方法忽略了样本的局部分布,并且该算法理论上是在无限样本下进行判别分析,忽略了对实际样本数量的考虑。在此基础上我们提出一种在有限样本下基于概率的两层自适应度量算法(PTLNN)并将其应用到烟雾检测。在 PTLNN 分类器的低层,我们使用欧氏距离来确定一个未标记的样本的局部子空间;然后在 PTLNN 分类器的高层,AdaBoost 在未标记样本局部子空间进行信息提取。PTLNN 算法以最小化平均绝对误差为原则,结合 AdaBoost 和 KNN 算法的优势,在有限样本下充分考虑样本分布来降低分类错误率,在视频烟雾检测中表现出良好的效果。

2.3.1 最小绝对误差进行距离度量学习

在二分类问题中,设 x 是要预测的类标签未知的样本点, x' 是 x 的最邻近点。对于一般的最近邻法,未知样本 x 被错分的概率是^[15]:

$$\begin{aligned} P_N(e|x) &= P(w_1|x)P(w_2|x') + P(w_2|x)P(w_1|x') \\ &= P(w_1|x)[1 - P(w_1|x')] + P(w_2|x)P(w_1|x') \\ &= 2P(w_1|x)P(w_2|x) + [P(w_1|x) - P(w_2|x)] \\ &\quad \cdot [P(w_1|x) - P(w_1|x')] \end{aligned} \quad (5)$$

其中, N 表示训练样本的数量, w_1, w_2 表示类标签。当训练样本的数量 $N \rightarrow \infty$ 时,渐进条件错误率为:

$$P(e|x) = \lim_{N \rightarrow \infty} P_N(e|x) = 2P(w_1|x)P(w_2|x) \quad (6)$$

这样,式(5)和式(6)都表示最近邻法的条件错误率,其中式(5)是在有限样本条件下,而式(6)则是针对无限样本,考虑两者之间的误差,可得:

$$P_N(e|x) - P(e|x) = [P(w_1|x) - P(w_2|x)] \cdot [P(w_1|x) - P(w_1|x')] \quad (7)$$

则在有限样本和无限样本训练样本下的平均绝对误差的误差率为:

$$E\{|P_N(e|x) - P(e|x)| | x\} \quad (8)$$

定义:

$$\varphi(x, x') = |P(w_1|x) - P(w_1|x')| \quad (9)$$

那么 $\varphi(x, x')$ 和 $P(w_1|x) - P(w_1|x')$ 之间的对应关系如图 6 所示。




图 6 $\varphi(x, x')$ 对应关系

由于 $[P(w_1|x) - P(w_2|x)]$ 在式(7)中是一个常数项,那么最小化 $|P_N(e|x) - P(e|x)|$ 相当于最小化 $\varphi(x, x')$ 。通常,可以通过增加训练样本的数量来最小化 $\varphi(x, x')$,文献[14]提出在不增加训练样本的数量情况下最小化 $\varphi(x, x')$,定义一个距离量 $dis = |f(x) - f(x')|$,其中 $f(x)$ 为 AdaBoost

建立的强分类器。在无限样本下 $f(x) = \frac{1}{2} \log(\frac{P(1|x)}{P(-1|x)})$,其中 $P(1|x)$ 为样本 x 标签为 1 的概率,而 $P(-1|x)$ 为样本 x 标签为 -1 的概率,则 $dis = \frac{1}{2} |\log(\frac{P(1|x)}{P(-1|x)}) - \log(\frac{P(1|x')}{P(-1|x')})|$ 即为定义的距离量。然而该距离是在无限样本下的理论距离,在现实中无限数量的样本是不存在的。在本文中,我们试图定义一个新的距离量 $D'(x, x')$ 同样不增加训练样本的数量来最小化 $\varphi(x, x')$ 。现在我们定义两个函数,在无限样本下:

$$e(x, x') = \frac{P(w_1|x)}{P(w_1|x')} \quad (10)$$

有限样本下:

$$e'(x, x') = \frac{P'(w_1|x)}{P'(w_1|x')} \quad (11)$$

其中, $P(w_1|x)$ 为无限样本下 x 的标签为 w_1 的概率, $P(w_1|x')$ 为无限样本下 x 的近邻样本 x' 的标签为 w_1 的概率,而 $P'(w_1|x)$ 和 $P'(w_1|x')$ 分别为在有限样本下 x 和 x' 的标签为 w_1 的概率。

定义函数:

$$\gamma = [e'(x, x') - e(x, x')]^2 \quad (12)$$

该函数表示样本 x 和其近邻在无限样本和有限样本下,标签为 w_1 的概率比之差。

γ 与 $e'(x, x') - e(x, x')$ 之间的对应关系如图 7 所示。




图 7 γ 对应关系图

对于 $\varphi(x, x')$, 当 $P(w_1|x) = P(w_1|x')$ 时, 得到 $\varphi(x, x') = |P(w_1|x) - P(w_1|x')| = 0$, 而当 $\gamma = 0$ 时, 可以推出 $e'(x, x') = e(x, x')$, 对比图 6 与图 7 可以看出, 图 6 和图 7 有相同的变化趋势。对于一个给定训练数据集, 下面两个最优化问题有相同的最优解:

$$\begin{aligned} \min \varphi(x, x') \quad \text{s. t. } \varphi(x, x') &= |P(w_1|x) - P(w_1|x')| \\ \text{和 } \min \gamma \quad \text{s. t. } \gamma &= [e'(x, x') - e(x, x')]^2 \end{aligned}$$

也就是说, 在确定一个未知点的近邻时, 我们可以使用 γ 代替 $\varphi(x, x')$ 来求解。

现在讨论如何最小化 γ 。首先对函数 $\gamma = [e'(x, x') - e(x, x')]^2$ 进行积分, 定义:

$$\begin{aligned} \aleph &= \iint [e'(x, x') - e(x, x')]^2 P(w_1|x') dx dx' \\ &= \iint e^2(x, x') P(w_1|x') dx dx' - 2 \iint e(x, x') e'(x, x') \\ &\quad \cdot P(w_1|x') dx dx' + \iint e'^2(x, x') P(w_1|x') dx dx' \end{aligned} \quad (13)$$

其中, 被积函数添加一个正数因子 $P(w_1|x')$ 可以方便化简, 且对最优解不造成影响。

由于 $\iint e'^2(x, x')P(w_1|x')dx dx'$ 恒为正值, 因此我们可以将其删除而对函数变化趋势不造成影响, 则式(13)转换为:

$$\aleph' = \iint e^2(x, x')P(w_1|x')dx dx' - 2 \iint e(x, x')e'(x, x') \cdot P(w_1|x')dx dx' \quad (14)$$

将式(10)和式(11)代入式(14)则可以转化为:

$$\begin{aligned} \aleph' &= \iint e(x, x')P(w_1|x)dx dx' - 2 \iint e'(x, x')P(w_1|x)dx dx' \\ &= \int E_x[e(x, x')]dx' - 2 \int E_x[e'(x, x')]dx' \\ &= \int \frac{1}{N_x} \sum_{i=1}^{N_x} e(x_i, x')dx' - 2 \int \frac{1}{N_{x'}} \sum_{i=1}^{N_{x'}} e'(x_i, x')dx' \\ &= \frac{1}{N_{x'}} \sum_{j=1}^{N_{x'}} \frac{1}{N_x} \sum_{i=1}^{N_x} e(x_i, x_j') - 2 \frac{1}{N_{x'}} \sum_{j=1}^{N_{x'}} \frac{1}{N_x} \sum_{i=1}^{N_x} e'(x_i, x_j') \\ &= \frac{1}{N_x} \frac{1}{N_{x'}} \sum_{i=1}^{N_x} \sum_{j=1}^{N_{x'}} [e(x_i, x_j') - 2e'(x_i, x_j')] \end{aligned} \quad (15)$$

由此可知, 我们只需将 $e(x_i, x_j') - 2e'(x_i, x_j')$ 最小化, 即可求得 $\aleph'$ 的最小值。

定义新的距离量:

$$D'(x, x') = |e(x, x') - 2e'(x, x')| \quad (16)$$

将式(10)和式(11)代入式(16)可得:

$$D'(x, x') = \left| \frac{P(w_1|x)}{P(w_1|x')} - 2 \frac{P'(w_1|x)}{P'(w_1|x')} \right| \quad (17)$$

式(17)即是定义的最近邻算法使用的新距离量。

现在专注如何求得 $D'(x, x')$ 。先探讨条件概率和 AdaBoost 之间的关系。AdaBoost 通过基础分类器 $h(x)$ 的线性组合构建分类器 $f(x)$ 来最小化 $\frac{1}{N} \sum_{i=1}^N \exp(-y_i f(x_i))$ 的经验风险, 这里 y_i 表示输入样本点 x_i 的类属性。假设如果 $x_i \in w_1$, 则 $y_i = -1$, 否则 $y_i = 1$ 。

对于一个给定的输入值 x 的类标签, 设 $P(y|x)$ 表示其条件概率。假设样本是独立同分布的, 当样本数量趋于无穷时 ($N \rightarrow \infty$), 经验风险的损失函数期望满足大数定理:

$$\begin{aligned} \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N \exp(-y_i f(x_i)) \\ &= \int_{x, y=\pm 1} \sum P(y|x) \exp(-yf(x)) dx \\ &= E(\exp(-yf(x))) \end{aligned} \quad (18)$$

通过最小化风险函数 $E(\exp(-yf(x)))$ 来推导分类器 $f(x)$, 被积函数式(18)在 $f(x)$ 处取得最小值, 满足等式:

$$\frac{\partial [\sum_{y=\pm 1} P(y|x) \exp(-yf(x))]}{\partial f(x)} = 0 \quad (19)$$

则:

$$\begin{aligned} \frac{P(1|x)}{P(-1|x)} &= \frac{\exp(f(x))}{\exp(-f(x))} = \exp(2f(x)) \\ \Rightarrow P(-1|x) &= \frac{1}{1 + \exp(2f(x))} \end{aligned} \quad (20)$$

即:

$$P(w_1|x) = \frac{1}{1 + \exp(2f(x))} \quad (21)$$

在上面的讨论中, 我们知道 $P(y|x)$ 表示在无限样本下的

理论条件概率, 而在实际有限样本下, 设条件概率为 $P'(y|x)$ 。由贝叶斯公式^[16]可知:

$$P'(w_j|x) = \frac{\rho'(x|w_j)P'(w_j)}{\rho'(x)} \quad (22)$$

其中, $\rho'(x|w_j)$ 表示 x 的状态条件概率密度函数——在真实类别为 w_j 的条件下 x 的概率密度函数, 而 $P'(w_j)$ 表示类别处于状态 w_j 时的先验概率。

在两类问题的状况下 $\rho'(x) = \sum_{j=1}^2 \rho'(x|w_j)P'(w_j)$ 。

对于概率密度函数 $\rho'(x|w_j)$ 的估计, 大多数研究采用假设概率密度函数进行参数估计的方式, 如 Xu 等人提出的 KMAP^[17] 算法即是假设高斯分布来进行研究。然而在许多实际的模式识别的应用场合, 采用的假设条件并不总是成立, 非参数概率密度估计由于具有更好的灵活性而被广泛研究和应用^[16,18], 因此我们采用 Parzen 窗方式。本文选择标准正态窗作为核函数, 则概率密度函数的估计公式为:

$$\rho'(x|w_j) = \frac{1}{N} \sum_{n=1}^N K(x, x_n) \quad (23)$$

其中, $K(x, x_n) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\{-\frac{1}{2}(x - x_n)^T \Sigma^{-1}(x - x_n)\}$ 。现在我们已经定义了一个最小化的平均绝对误差距离量, 并对新距离量 $D'(x, x')$ 完成了讨论, 下面将提出新的算法过程。

2.3.2 算法步骤

基于概率的两层近邻分类自适应度量算法 (PTLNN) 先用最近邻算法建立一个局部子空间, 即在低层我们使用欧氏距离为每个测试数据选定 k 个近邻样本组成子空间, 这样可以限制 AdaBoost 信息提取时过度延伸; 然后在 PTLNN 分类器的高层, 用上文中的新距离量从子空间中选定近邻来确定测试数据标签。新距离量将 KNN 与 AdaBoost 相结合, 使 AdaBoost 在子空间的信息提取顺利进行, 并且在信息提取过程中通过概率来评估数据分布。

综上所述, 本文提出的算法描述如下:

1. 利用 AdaBoost 算法建立强分类器 $f(x)$, 其中 T 表示分类器的个数。

2. 在低层, 用最近邻算法为每个测试数据选定 k_1 个近邻, 建立一个局部子空间 $R(x) = \{x' | D(x, x') \leq d_{(k_1)}\}$, 其中 $d_{(k_1)}$ 是 $\{D(x, x')\}^N$ 的第 k_1 个值, $D(x, x')$ 是为了判别最近邻的欧氏距离量。

3. 在高层, 用新的距离量 $D'(x, x')$ 将 AdaBoost 与 KNN 算法相结合, 从子空间 $R(x)$ 中选定 k_2 个近邻建立一个新的局部子区域 $R'(x) = \{x' | D'(x, x') \leq d_{(k_2)}\}$, 其中 $d_{(k_2)}$ 表示 $\{D'(x, x')\}^N$ 的第 k_2 个值, $D'(x, x')$ 是由式(13)定义的了判别最近邻的新距离量。

4. 对于给定的观测值 x 判定其标签 y : $y = \text{sign}(\text{ave}_{x' \in R'(x)} y')$ 。

3 实验与分析

本次实验均在 MATLAB 7.10.0 平台下完成, 实验环境为 CPU Intel Core(TM) i3-3240 3.40GHz, 内存为 4G, 视频分辨率为 240×320 , 每一帧图像分为 60×60 像素的小块, 因

此图像被分为 3×4 块,人工标记每块是否存在烟雾。本文实验中的烟雾视频来源于土耳其 Bilkent 大学机器视觉研究室 (<http://signal.ee.bilkent.edu.tr/VisiFire/>) 和视频监控在线资源库 (http://imagelab.ing.unimore.it/visor/video_categories.asp)。图 8 所示为 6 组实验视频截取第 60 帧图像的场景,从左至右、从上至下依次为 Video1—Video6。




图 8 实验视频场景

实验中每组图像数据为从相应视频中每 6 帧取一帧图像组成的数据集,然后将每个数据集随机分成两个大小相等的子集,其中一个为训练集另一个为测试集,数据集详细信息如表 1 所列。本文将 PTLNN 算法与文献[11]中采用的 SVM、文献[12]中使用的 AdaBoost 以及文献[14]中的 TLNN 算法进行烟雾检测,采用离散余弦变换和离散小波变换两种特征提取方式进行对比试验。在 PTLNN 和 TLNN 算法中,近邻数量关系设置为 $k_1 = 2 \cdot k_2 + 1$,此处设置 $k_2 = 3$,我们以单特征值训练泛化型 AdaBoost 的弱分类器,为减小训练时间我们将最大训练迭代次数设置为 $T = 30$ 。实验中 SVM 分类算法采用 MATLAB 自带函数,其核函数类型选用径向基函数(RBF),优化参数中最大迭代次数设置为 1500,在使用离散小波变换(DWT)进行特征提取时,我们采用 bior 2.2 小波对图像进行变换。

表 1 实验数据详细信息

视频	总帧数	帧速率(帧/s)	训练用帧数	测试用帧数
Video1	630	10	53	52
Video2	900	10	75	75
Video3	2326	24	194	193
Video4	1400	10	117	116
Video5	1835	25	153	152
Video6	900	15	75	75

实验中我们用训练时间、测试时间、敏感度、特异度、准确率对算法进行性能评估,相关定义如下:

$$\text{敏感度} = \frac{TP}{TP + FN}$$

$$\text{特异度} = \frac{TN}{TN + FP}$$

$$\text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

其中, TP 、 TN 、 FP 、 FN 分别为真正、真负、假正、假负。

表 2 所列为 6 组视频用支持向量机(SVM)、AdaBoost、TLNN 和 PTLNN 4 种算法并结合离散小波变换(DWT)和离散余弦变换(DCT)两种方式进行实验的结果,从训练时间、检测时间、敏感度、特异度和准确率 5 个方面对算法性能进行了评估。

表 2 视频烟雾检测结果

Video 1					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	1.9157	0.0252	0.9440	0.8792	90.71
DWT+AdaBoost	37.3061	0.0023	0.9414	0.9174	92.79
DWT+TLNN	47.2289	0.0091	0.9564	0.9226	93.75
DWT+PTLNN	38.3278	0.0199	0.8791	0.9744	93.27
DCT+SVM	9.0481	0.0296	0.9690	0.9481	95.67
DCT+AdaBoost	40.5948	0.0021	0.9291	0.9410	93.59
DCT+TLNN	41.4823	0.0102	0.9098	0.9500	93.43
DCT+PTLNN	41.6499	0.0214	0.9552	0.9747	96.63
Video 2					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	2.2526	0.0662	0.3370	0.9904	79.22
DWT+AdaBoost	84.1120	0.0053	0.7793	0.9318	88.11
DWT+TLNN	76.8838	0.0155	0.7508	0.9580	88.22
DWT+PTLNN	87.1342	0.0334	0.7191	0.9750	89.00
DCT+SVM	49.7944	0.0512	0.9106	0.8913	89.78
DCT+AdaBoost	81.3874	0.0031	0.7840	0.9625	90.56
DCT+TLNN	83.6817	0.0120	0.7260	0.9836	90.00
DCT+PTLNN	84.5596	0.0344	0.7909	0.9772	91.78
Video 3					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	839.81140	0.3275	0.9951	0.9341	93.31
DWT+AdaBoost	464.3445	0.0062	0.9928	0.9870	99.05
DWT+TLNN	442.8708	0.1086	0.9993	0.9877	99.48
DWT+PTLNN	508.4997	0.1031	0.9828	0.9989	98.92
DCT+SVM	1653.3861	0.3161	1	0.9835	99.35
DCT+AdaBoost	478.4937	0.0042	1	0.9923	99.70
DCT+TLNN	505.1751	0.0407	0.9972	0.9934	99.57
DCT+PTLNN	513.7287	0.0925	0.9965	0.9989	99.74
Video 4					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	170.8285	0.1235	0.9920	0.8683	93.53
DWT+AdaBoost	162.6320	0.0291	0.9852	0.9522	96.98
DWT+TLNN	163.3490	0.0234	0.9757	0.9585	96.77
DWT+PTLNN	172.5741	0.0610	0.9314	0.9784	95.33
DCT+SVM	202.5411	0.1061	0.9864	0.9726	97.99
DCT+AdaBoost	178.6575	0.0042	0.9751	0.9444	96.12
DCT+TLNN	182.5522	0.0234	0.9523	0.9757	96.26
DCT+PTLNN	187.7116	0.0580	0.9711	0.9841	97.70
Video 5					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	289.6734	0.2120	0.9615	0.8696	90.63
DWT+AdaBoost	292.6588	0.0111	0.8694	0.9451	91.56
DWT+TLNN	301.1769	0.0365	0.8747	0.9769	93.53
DWT+PTLNN	309.8579	0.0684	0.8144	0.9901	92.54
DCT+SVM	530.3895	0.2306	0.9836	0.8612	91.45
DCT+AdaBoost	330.6995	0.0091	0.8309	0.9478	89.97
DCT+TLNN	337.5796	0.0304	0.8783	0.9816	93.70
DCT+PTLNN	349.4246	0.0724	0.9574	0.9860	97.42
Video 6					
	训练时间 (s)	检测时间 (s)	敏感度	特异度	准确率 (%)
DWT+SVM	1.0414	0.0614	0.9924	0.5837	88.11
DWT+AdaBoost	71.0974	0.0035	0.9726	0.8612	93.33
DWT+TLNN	71.1717	0.0157	0.9608	0.8359	92.44
DWT+PTLNN	74.1159	0.0362	0.9177	0.9811	94.00
DCT+SVM	27.8673	0.0567	0.9554	0.9338	94.89
DCT+AdaBoost	73.4177	0.0059	0.9743	0.8231	92.78
DCT+TLNN	77.1983	0.0125	0.9410	0.9241	93.56
DCT+PTLNN	76.0825	0.0357	0.9695	0.9531	96.44

从实验结果看,6组视频中当SVM算法的数据集较小时如Video 1、Video 2和Video 6,训练时间比其他两种算法明显要少;然而当数据集较大时,如Video3和Video5,训练时间显著增加,大大超过其他算法。在检测时间方面,AdaBoost算法检测时间耗时最短,而TLNN和PTLNN算法次之,两种算法相差不大,SVM检测时间最长也明显超过其他算法;关于烟雾检测的实时性方面,PTLNN算法在6组视频中均在0.1s内完成图像检测,完全满足烟雾检测的实时性要求。在敏感度和特异度方面,AdaBoost、TLNN和PTLNN算法性能无明显差距,PTLNN算法在特异度方面表现更优,而SVM算法在Video2和Video6中敏感度和特异度较差。精确度是烟雾检测的关键,从6组实验数据的结果看,4种算法在采用离散小波变换作为特征进行检测时,AdaBoost、TLNN和PTLNN算法分别在1组、3组和2组数据中取得最好结果,虽然TLNN算法结果略好,但PTLNN算法与TLNN实验结果差别并不明显;在采用离散余弦变换作为特征进行检测时,PTLNN算法在5组视频数据中取得了最优结果,在Video 4中取得次优的结果,这表明PTLNN算法在采用余弦变换时有更好的检测精度。另外,在4种算法用离散余弦变换(DCT)和离散小波变换(DWT)两种形式组成的8种检测方式中,我们发现AdaBoost与TLNN算法用两种方式得出的实验结果差距不大,而PTLNN算法在采用离散余弦变换作为特征进行检测时,准确率较采用离散小波变换时有了很大提升,比其他方法的实验结果有更明显的优势,性能更优。

从上述结果可以看出,采用PTLNN算法结合离散余弦变换方式进行烟雾检测可以取得更好的检测结果,既满足视频烟雾检测实时性,又在检测精度方面有了明显提升。

结束语 本文提出了一种新的基于概率的两层自适应度量算法(PTLNN)来对视频烟雾进行检测,PTLNN算法以最小化平均绝对误差为原则,结合AdaBoost和KNN算法的优势,充分考虑局部和全局的样本分布,能明显提升分类精度。我们采用离散余弦变换(DCT)和离散小波变换(DWT)两种方式与其它算法进行对比验证,发现在采用离散余弦变换并结合PTLNN算法在视频烟雾检测方面有更好的效果。然而该方法在训练时间和测试时间方面上仍有不足,虽然满足视频烟雾检测的实时性要求,但训练和测试时间较AdaBoost算法要长,因此仍有很大改进空间。

参考文献

- [1] Fang Lu-ming, Xu Ai-jun, Tang Li-hua. Study of the key technology of forest fire prevention based on a cooperation of video monitor and GIS[J]. Natural Computation, 2008, 5: 391-396
- [2] Huang Fu-zhen, Wu Hai-tao. Video flame detection based on color and contour features[C]//Proceeding of the 31st Chinese Control Conference(CCC). Hefei, China, 2012: 3668-3671
- [3] Chen Juan, He Ya-ping, Wang Jian. Multi-feature fusion based fast video flame detection[J]. Building and Environment, 2010, 45(5): 1113-1122
- [4] Toreyin B U, Dedeoglu Y, Cetin A E. Flame detection in video using hidden markov models[C]//Proc of IEEE International Conference on Image Processing. IEEE Press, 2005, 2: 1230-1233
- [5] Habiboglu Y, Gunay O, Cetin A E. Flame detection method in video using covariance descriptors[C]//2011 IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP). 2011: 1817-1820
- [6] Li Ma, Wu Kai-hua, Zhu L. Fire smoke detection in video images using Kalman filter and Gaussian mixture color model[C]//IEEE Computer Press Artificial Intelligence and Computational Intelligence. Las Vegas, USA, 2010: 484-487
- [7] Ko B C, Kwak J, Nam J. Wildfire smoke detection using temporal-spatial features and random forest classifiers[J]. Optical Engineering, 2012, 51(1): 1-10
- [8] 袁非牛, 张永明, 刘士兴, 等. 基于累积量和主运动方向的视频烟雾检测方法[J]. 中国图象图形学报, 2008, 13(4): 808-813
- [9] Yang Jing, Cheng Feng, Zhang Wei-dong. Visual-based smoke detection using support vector machine[C]//Fourth International Conference on Natural Computation. Jinan, China, 2008: 301-305
- [10] 吴梦宇, 罗琴娟, 韩摇宁. 基于多运动特征的森林火灾烟雾图像识别算法[J]. 北京林业大学学报, 2013, 35(3): 154-158
- [11] Gubbi J, Marusic S, Palaniswami M. Smoke detection in video using wavelets and support vector machines[J]. Fire Safety Journal, 2009, 44(8): 1110-1115
- [12] Wang Zhi-jie, Salah B, Zhang Hong. Discrete wavelet transform based steam detection with Adaboost[C]//International Conference on Information and Automation (ICIA). Shenyang, China, 2012: 542-547
- [13] 盛家川. 基于小波变换的国画特征提取及分类[J]. 计算机科学, 2014, 41(2): 317-319
- [14] Gao Y, Pan J, Ji G, et al. A novel two-level nearest neighbor classification algorithm using an adaptive distance metric[J]. Knowledge-Based Systems, 2012, 26: 103-110
- [15] 边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2000
- [16] Duda R O, Hart P E, Stork D G. Pattern classification [M]. John Wiley & Sons, 2012
- [17] XU Zeng-lin, Huang Kai-zhu, Zhu Jian-ke, et al. A novel kernel-based maximum a posteriori classification method[J]. Neural Networks, 2009, 22(7): 977-987
- [18] Liu Z, Xue Y, Shen L, et al. Nonparametric saliency detection using kernel density estimation[C]//International Conference on Image Processing (ICIP). HongKong, 2010: 253-256
- [15] Lin Z, Chen M, Ma Y. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[J]. arXiv preprint arXiv:1009.5055, 2010
- [16] Vidal R, Favaro P. Low rank subspace clustering (LRSC)[J]. Pattern Recognition Letters, 2014, 43(1): 47-61
- [17] Candes E J, Wakin M B, Boyd S P. Enhancing sparsity by reweighted l_1 minimization[J]. Journal of Fourier analysis and applications, 2008, 14(5/6): 877-905
- [18] Lin Z, Chen M, Ma Y. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[J]. arXiv preprint arXiv:1009.5055, 2010
- [19] Peng Y, Suo J, Dai Q, et al. Reweighted Low-Rank Matrix Recovery and its Application in Image Restoration[J]. IEEE Transactions on Cybernetics, 2014, 44(12): 2418-2430

(上接第300页)