

中图法分类号: TN911.23 文献标志码: A 文章编号: 1006-8961(2011)09-1643-07

论文索引信息: 郭春生, 朱明. 面向特征的ICA和HP滤波实现视频异常事件检测[J]. 中国图象图形学报, 2011, 16(9): 1643-1649

面向特征的ICA和HP滤波实现 视频异常事件检测

郭春生, 朱明

(杭州电子科技大学通信工程学院, 杭州 310018)

摘要:针对室外环境下光照亮度变化、阴影和树木遮挡等问题,对利用隐马尔可夫模型进行视频异常事件检测的影响,提出基于独立分量分析(ICA)和HP(Hodrick-Prescott)滤波器的隐马尔可夫模型视频异常事件检测方法。该方法首先利用ICA构造正常视频的特征子空间,将图像序列投影到特征子空间上得到投影序列,实现数据降维;然后利用HP滤波器滤除投影序列中环境变化引起的趋势分量;最终克服不利的环境因素,有效改善隐马尔可夫模型的视频异常事件检测性能。机动车辆禁行路段视频的检测实验表明,该方法能够在复杂的室外环境下较好地检测出异常事件。

关键词:异常事件检测;独立分量分析;HP滤波器;隐马尔可夫模型

Video unusual event detection using feature-oriented ICA and HP filter

Guo Chunsheng, Zhu Ming

(College of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018)

Abstract: Many factors in outdoor environment, such as light, shadows and trees blocks etc. will affect the video unusual event detection based on the hidden Markov model (HMM). So using the independent component analysis (ICA) and HP (Hodrick-Prescott) filter, a new HMM video unusual event detection method is proposed. This method first employed ICA to construct a normal video feature subspace, and projected the image sequence into this subspace to achieve data reduction. Then the trend component in feature sequence caused by the environment factors is cancelled by the HP filter. So to overcome the adverse environmental factors, the effect of the proposed method is improved. Using the video data in a forbidden road for motor vehicles, the test result shows the proposed method can detect the video unusual events effectively in the complex outdoor environments.

Keywords: unusual events detection; independent component analysis (ICA); HP filter; hidden Markov model (HMM)

0 引言

近年来,视频监控系统正广泛应用于诸如银行、

商店、停车场、居民小区和道路等的监控和管理中。如何从此类视频中自动检测异常事件,作为智能视频监控系统中的关键技术,目前正成为国内外学者研究的热点。

收稿日期:2010-02-04;修回日期:2010-10-20

基金项目:国家自然科学基金项目(60702018)。

第一作者简介:郭春生(1971—),男,副教授。2002年在南京航空航天大学获得通信与信息系统专业博士学位,主要研究方向统计信号处理。E-mail: guo.chsh@gmail.com。

异常事件的检测方法主要有基于模型的方法和基于分类器的方法两种^[1]。基于模型的方法强调对异常事件的检测而非分类,它对正常事件建立一定的模型,通过比较待检测事件与该模型的符合程度来判断其是否为异常事件。该方法适用于异常事件样本不易获取的情况,常用的模型有隐马尔可夫模型(HMM)和高斯混合模型(GMM),如 Jager 等人^[2]利用 HMM 监控焊接过程中的异常事件;Atrey 等人^[3]利用 GMM 对音频中的尖叫、敲门等异常事件进行检测。基于分类器的方法通过构建合理的分类器,实现对正常事件和异常事件的区分,如胡芝兰等人^[4]根据不同行为运动方向具有不同的规律性,采用支持向量机(SVM)分类器对视频中异常行为进行检测;Jan 等人^[5]利用人工神经网络(ANN)分类器,检测停车场中人的异常可疑行为等。

视频图像中包含大量的冗余信息,为了降低数据维数、提高运算效率,需要对图像进行特征提取。常用的特征提取方法有主分量分析(PCA)^[2]和独立分量分析(ICA)^[6-7]等。

在异常事件样本不易获取的情况下,基于 HMM 的视频异常检测^[2,8-10]是一种有效视频异常事件检测方法。但在自然场景下,由于光照强度变化、阴影变化等因素导致该方法的性能差异较大。本文针对自然场景的视频异常检测问题,提出基于 ICA 和 HP(Hodrick-Prescott)^[11]滤波的特征提取方法,解决视频异常检测中光照变化和复杂场景的影响。为验证算法的有效性,利用某段机动车辆禁行路段的视频监控数据,将该路段上通行的行人、自行车和电瓶车等非机动车视为正常事件,将该路段上通行的机动车辆视为异常事件,进行视频异常事件检测。实验结果表明,该算法能够有效解决自然场景条件下的视频异常检测。

1 算法的原理和实现

如图 1 所示的算法处理框图,上半部分是模型训练部分,下半部分是视频异常检测部分。算法首先将经过预处理后的图像序列投影到基于 FastICA^[12]算法获取的特征子空间中得到特征序列;然后利用 HP 滤波器对特征序列进行趋势滤波,有效地削弱各种环境因素对特征序列稳定性的影响;最后利用 HMM 对特征序列建模和视频异常检测。




图 1 算法的处理框图

Fig. 1 The flowchart of the algorithm

1.1 图像预处理

图像预处理包括滤波和规格化处理两步。对视频中的图像进行维纳滤波,可以滤除图像中的随机噪声;由于光照和天气等因素的影响,即使在同一场景下采集的图像,图像间的灰度和对比度也会存在较大差异,需要对图像进行灰度规格化处理^[13]。

设 I 为 $M \times N$ 的原始图像, $I(i, j)$ 表示图像 I 中像素点 (i, j) 的灰度值; G 为灰度规格化后的图像, $G(i, j)$ 表示图像 G 中像素点 (i, j) 的灰度值,则灰度规格化的计算如下式

$$G(i, j) = \begin{cases} \mu_0 + G'(i, j) & I(i, j) > \mu_x \\ \mu_0 - G'(i, j) & I(i, j) \leq \mu_x \end{cases} \quad (1)$$

式中, $G'(i, j) = \sqrt{\frac{\sigma_0^2 \times (I(i, j) - \mu_x)^2}{\sigma_x^2}}$

$$\mu_x = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N I(i, j)$$

$$\sigma_x^2 = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (I(i, j) - \mu_x)^2$$

这里 μ_x 和 σ_x^2 分别是原始图像的灰度均值和方差, μ_0 和 σ_0^2 分别是期望的灰度均值和方差。

1.2 图像的特征抽取

ICA 将观测数据分解为一组相互独立的非高斯信号的线性组合^[14]。设 m 帧观测图像 X_i ($i = 1, 2, \dots, m$) 分解为 n 帧相互独立的基图像 S_i ($i = 1, 2, \dots, n$) 的线性组合,即

$$X = AS = \begin{bmatrix} \sum_{i=1}^n a_{1,i} s_i \\ \sum_{i=1}^n a_{2,i} s_i \\ \vdots \\ \sum_{i=1}^n a_{m,i} s_i \end{bmatrix} \quad (2)$$

这里 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]^T, \mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n]^T, \mathbf{x}_i, \mathbf{s}_i$ 是由观测图像 \mathbf{X}_i 和基图像 \mathbf{S}_i 逐列拼接而成的列向量,混合矩阵

$$\mathbf{A} = \begin{bmatrix} a_{1,1} & \dots & a_{1,n} \\ a_{2,1} & \dots & a_{1,n} \\ \vdots & & \vdots \\ a_{m,1} & \dots & a_{m,n} \end{bmatrix}$$

ICA 通过求解分离矩阵 \mathbf{W} , 计算信号 \mathbf{S} 的估计 $\mathbf{Y} = \mathbf{W}\mathbf{X} = \mathbf{W}\mathbf{A}\mathbf{S}$ (3)

式中, $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$, 其行向量代表相互独立的基图像, 构造 1 个特征子空间; 分离矩阵 $\mathbf{W} = [w_1, w_2, w_n]^T$ 。

设待处理图像 \mathbf{F}_j 逐列拼接为 1 维列向量 \mathbf{f}_j , 将其投影到特征子空间上, 即 \mathbf{f}_j 可用一组相互独立的基图像线性表示, 即

$$\mathbf{f}_j = b_{j,1}y_1 + b_{j,2}y_2 + \dots + b_{j,n}y_n \quad (4)$$

式中, $b_{j,1}, b_{j,2}, \dots, b_{j,n}$ 是 \mathbf{f}_j 在特征子空间 \mathbf{Y} 上的投影系数, 满足

$$\mathbf{b}_j = [b_{j,1}, b_{j,2}, \dots, b_{j,n}]^T = \mathbf{Y}\mathbf{f}_j \quad (5)$$

利用投影系数 \mathbf{b}_j 表示图像 \mathbf{F}_j , 实现特征抽取, 极大压缩了原始数据量。

分离矩阵 \mathbf{W} 求解利用 FastICA 算法, 通过计算近似负熵的极大值。通常采用的近似负熵 $J(y_i)$ 为 $J(y_i) \propto \{E[G(y_i)] - E[G(v_i)]\}^2$ (6)

式中, G 为非二次函数, 如 $G(y_i) = -\exp(-\frac{y_i^2}{2})$ 或 $G(y_i) = \frac{1}{a} \ln(\cosh(ay_i))$; v_i 是与 y_i 具有相同均值和协方差矩阵的高斯变量。

数据 \mathbf{X} 经过预处理后, 限定 w_i 的模为 1, 利用

$$\mathbf{F} = \begin{bmatrix} 1 & -2 & 1 & 0 & \dots & 0 \\ -2 & 5 & -4 & 1 & 0 & \dots \\ 1 & -4 & 6 & -4 & 1 & 0 \\ 0 & 1 & -4 & 6 & -4 & 1 & 0 \\ \vdots & \ddots & & & & & \\ \vdots & & & & & & \\ 0 & \dots & 0 & 1 & -4 & 6 & -4 & 1 & 0 \\ 0 & \dots & \dots & 0 & 1 & -4 & 6 & -4 & 1 \\ 0 & \dots & \dots & \dots & 0 & 1 & -4 & 5 & -2 \\ 0 & \dots & \dots & \dots & \dots & 0 & 1 & -2 & 1 \end{bmatrix}$$

而 \mathbf{B}_j 和 \mathbf{B}_j^T 都是 $N \times n$ 的矩阵, 其中

$$\mathbf{B}_j = [b_j(1) \quad b_j(2) \quad \dots \quad b_j(N)]^T$$

牛顿迭代法, 得到 w_i 的迭代式为

$$w_{k+1} = E[\mathbf{X}g(w_i^k)^T \mathbf{X}] - E[g'((w_i^k)^T \mathbf{X})] \mathbf{w}_i^k \quad (7)$$

式中, 函数 $g(\cdot)$ 为 $G(\cdot)$ 的导数。为提高算法的稳定性, 在每次迭代后, 对 \mathbf{w}_i^{k+1} 进行归一化处理, 即 $\mathbf{w}_i^{k+1} = \mathbf{w}_i^{k+1} / \|\mathbf{w}_i^{k+1}\|$ 。

1.3 特征序列的 HP 滤波

在室外环境中, 光照强度的变化和阴影等因素将引起投影系数 b_j 的波动。所幸的是这种波动通常比较缓慢, 因此, 本文采用 HP 滤波器^[11] 来滤除特征序列的缓慢波动, 降低不相关因素对视频异常检测的影响。

HP 滤波器假定特征序列 $b_j(n)$ 是波动分量 $b_j^c(n)$ 和趋势分量 $b_j^T(n)$ 之和, 即 $b_j(n) = b_j^c(n) + b_j^T(n)$, 其中 $n = 1, 2, \dots, N$ 。趋势分量 $b_j^T(n)$ 通过极小化下式所示的目标函数来确定

$$\underset{b_j^T(n)}{\operatorname{argmin}} \left\{ \sum_{n=1}^N [b_j(n) - b_j^T(n)]^2 + \lambda \sum_{n=2}^{N-1} \{ [b_j^T(n+1) - 2b_j^T(n) + b_j^T(n-1)] \}^2 \right\} \quad (8)$$

式中, λ 是一常数。 λ 的取值越大, 得到的趋势分量 $b_j^T(n)$ 越平滑, 提取的趋势分量越粗糙, 但能更好地保留波动分量; 反之则能够更精确地提取趋势分量, 同时也会削弱波动分量。在实际应用中需要根据实际情况合理地选择 λ 值。

确定趋势分量 $b_j^T(n), n = 1, 2, \dots, N$, 可以分别利用 $b_j^T(n)$ 对式(8)求导取极值, 得到 N 个方程组, 可整理为下式所示的矩阵形式

$$\mathbf{B}_j = (\lambda \mathbf{F} + \mathbf{I}) \mathbf{B}_j^T$$

式中, \mathbf{F} 是 $N \times N$ 的矩阵,

$$\mathbf{F} = \begin{bmatrix} \dots & \dots & \dots & \dots & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \dots & 0 & 1 & -4 & 6 & -4 & 1 & 0 \\ \dots & \dots & 0 & 1 & -4 & 6 & -4 & 1 \\ \dots & \dots & \dots & 0 & 1 & -4 & 5 & -2 \\ \dots & \dots & \dots & \dots & 0 & 1 & -2 & 1 \end{bmatrix}$$

$$\mathbf{B}_j^T = [b_j^T(1) \quad b_j^T(2) \quad \dots \quad b_j^T(N)]$$

于是, 已知趋势分量 \mathbf{B}_j , 则波动分量 \mathbf{B}_j^c 可表示为

$$B_j^c = B_j - (\lambda F + I)^{-1} B_j \quad (9)$$

1.4 HMM 的建模和异常检测

HMM^[15] 是一个双重随机过程, 其中一个为隐含有有限状态的马尔可夫链, 描述状态之间的相互转换; 另一个描述状态和观测值之间的统计关系。设观测值序列为 $\mathbf{O} = [o_1, o_2, \dots, o_T]$, 相应的状态序列为 $\mathbf{Q} = [q_1, q_2, \dots, q_T]$, 其中 $o_i \in \Omega_o$, $q_i \in \Omega_q$, Ω_o 和 Ω_q 分别表示观测集合和状态集合; \mathbf{A} 为状态转移概率矩阵; \mathbf{B} 为给定状态条件下的观测值概率矩阵或观测概率密度函数; $\boldsymbol{\pi}$ 为初始状态概率矢量, 则 HMM 可使用五元组 $\boldsymbol{\Phi} = [\Omega_o, \Omega_q, \mathbf{A}, \mathbf{B}, \boldsymbol{\pi}]$ 来表示。

HMM 的建模就是根据一组正常事件的特征序列不断修正模型参数, 使 $P(\mathbf{O} | \boldsymbol{\Phi})$ 最大。因为没有解析法, 只能使用迭代法 (Baum-Welch 算法) 或最佳梯度法。

HMM 的阶数通常基于贝叶斯信息准则 (BIC)^[16] 来确定, 可表示为

$$C_{\text{BIC}} = \ln P(\mathbf{O} | \boldsymbol{\Phi}) - \frac{K}{2} \ln T \quad (10)$$


式中, \mathbf{O} 是观测序列, K 是模型 $\boldsymbol{\Phi}$ 中待估参数的个数, T 是观测序列数据集的大小。在给定模型 $\boldsymbol{\Phi}$ 条件下, 观测序列的对数似然值 $\ln P(\mathbf{O} | \boldsymbol{\Phi})$ 越大, 模型 $\boldsymbol{\Phi}$ 对观测数据的描述能力越强, 通常需要更高的模型阶数, 导致 HMM 复杂化。惩罚因子 $\frac{K}{2} \ln T$ 在 HMM 满足要求的情况下, 尽可能选择简单的模型。

在检测阶段, 采集到的未知图像序列经过预处理后投影到特征子空间上, 输出特征序列。将特征序列视为观测序列 \mathbf{O} , 根据 HMM 模型 $\boldsymbol{\Phi}$, 计算似然函数 $P(\mathbf{O} | \boldsymbol{\Phi})$, 即评价观测序列和模型的吻合程度, 通常采用“前向-后向”算法进行求解。当特征序列的概率 $P(\mathbf{O} | \boldsymbol{\Phi})$ 大于给定的阈值时, 认为该特征序列与模型相符合, 由正常事件图像序列所产生; 当特征序列的概率 $P(\mathbf{O} | \boldsymbol{\Phi})$ 小于给定的阈值时, 认为该特征序列与模型不符合, 由异常事件图像序列所产生。

2 实验结果及分析

利用自然环境下机动车辆禁行路段的视频监控数据验证算法的有效性。该组视频监控数据由 SAMSUNG S-1288 摄像头在不同时间、不同光照和

阴影条件下采集获得, 其帧率为每秒 6 帧, 分辨率为 320×240 。为了减少数据量, 对视频按时间顺序每 3 帧抽取一帧, 降低图像分辨率至 160×120 , 并将每 15 帧图像构成一段图像序列。全部数据库共包含 680 段图像序列, 其中前 100 段图像序列全部为正常事件, 作为训练集进行模型训练; 后 580 段中有 72 段图像序列存在异常事件, 作为测试数据。部分视频监控图像序列如图 2 所示。



(a) 不同时刻的正常图像序列




(b) 某一时刻的异常图像序列

图 2 部分视频监控图像序列

Fig. 2 Part of the video surveillance image sequences

2.1 图像预处理

先对采集到的图像进行维纳滤波, 然后进行灰度规格化, 灰度规格化的期望均值和方差由训练集中图像求得。某一预处理前后的图像如图 3 所示, 由图可知, 预处理可有效地调整图像的灰度均值和方差, 使后续处理具有统一的基准。



(a) 期望的图像 (b) 原始图像 (c) 预处理后的图像

图 3 图像预处理前后比较

Fig. 3 Images before and after pretreatment

2.2 FastICA 特征分析

FastICA 算法选择函数 $G(y_i) = \ln(\cosh y_i)$, 选取基图像的个数为 40, 对训练集图像序列进行特

征子空间分解。分离出的若干相互独立的基图像如图4所示。每一基图像都包含图像序列中的部分信息,而每一帧原始图像可表示为这些基图像的线性组合。




图4 若干分离出的基图像

Fig. 4 Several isolated base image

基图像的个数与检测率之间的关系如表1所示。基图像的个数过多或过少都会影响检测性能,主要是因为基图像的个数过多时,包含了大量干扰信号,而基图像的个数过少时,又丢失了图像的特征信息。实验结果表明,当基图像的数目为35~42时,识别率最高。

2.3 特征序列的 HP 滤波

将图像投影到 ICA 特征子空间上,需要对每段图像序列的投影系数分别进行 HP 趋势滤波。第13个基图像上的投影系数 $b_{13}(n)$ 在 HP 滤波前后的图像如图5所示,其中图5(a)为原始投影系数,图(b)为 HP 滤波后的波动分量, λ 取100。可以看出,HP 滤波器成功滤除了一些变化缓慢的干扰因素,使得所有系数都具有相同的基准,有利于视频异常事件的检测。

表1 基图像数量对检测性能的影响

Tab. 1 The effect of the number of base image to detection performance

基图像个数	10	20	34	35	40	42	43	50	80	160
检测率/%	73.61	87.50	91.67	94.44	94.44	94.44	93.06	88.89	83.33	69.44
误检率/%	4.02	3.64	2.92	2.89	2.73	2.76	2.71	2.54	2.49	2.38
平均检测时间/(μ s/段)	30.8	34.6	39.2	41.1	42.8	45.2	46.4	49.1	58.6	85.8




图5 HP 滤波前后投影系数

Fig. 5 The projection coefficient before and after the HP filter

2.4 HMM 训练和异常检测

算法采用高斯混合模型(GMM)表示给定状态条件下的观测概率密度函数,即状态 q_i 条件下观测值 o_k 的概率分布可记为

$$b_{q_i}(o_k) = \sum_{m=1}^M \omega_{q_i,m} p(o_k | \mu_{q_i,m}, \Sigma_{q_i,m}) \quad (11)$$

式中, M 为 GMM 中的高斯分量数目, $\omega_{q_i,m}$ 是 q_i 状

态下第 m 个高斯分量的权重, $p(o_k | \mu_{q_i,m}, \Sigma_{q_i,m})$ 是一个服从均值向量为 $\mu_{q_i,m}$ 、协方差矩阵为 $\Sigma_{q_i,m}$ 的多元高斯分布的概率密度函数。

在训练阶段,利用前100段图像序列投影系数的波动分量,采用 Baum-Welch 算法训练 HMM。模型的状态数 N 和高斯分量数 M 按照 BIC 准则来确定。当基图像的个数为40时,不同 N 和 M 对应的 BIC 值 ν_{BIC} 变化曲线如图6所示。从图中可以得到,当 $N > 25, M > 2$ 时,增加模型的状态数和高斯分量数,对提高 BIC 值贡献不大,因此,选择 $N = 25, M = 2$ 。

在测试阶段,将测试集图像序列投影系数的波动分量作为观测序列,输入到已训练好的 HMM,利用“前向-后向”算法计算对数似然度。当对数似然度低于给定的阈值时,认为该段视频中有异常事件。其中阈值等于训练阶段的对数似然度平均值减去其3倍方差。图7(a)给出了测试图像序列段异常事件(1)和正常事件(0)的实际情况;图7(b)给出了测试图像序列段的检测结果。实验结果表明,算法对异常事件的检测率可达94.44%,而对正常事件的误识率为2.73%。




图 6 不同 N 和 M 对应的 BIC 值

Fig. 6 The BIC value corresponding to different N and M

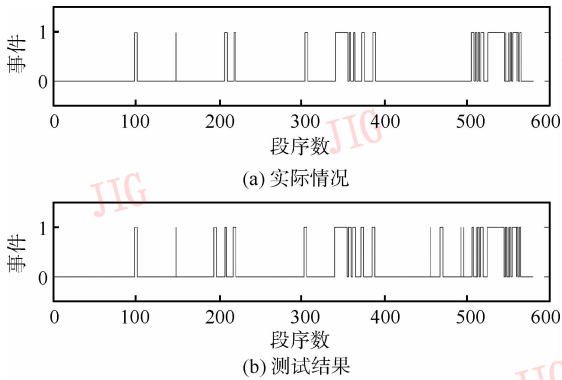



图 7 不同测试图像序列段的事件类别曲线图

Fig. 7 The curve of event type for test image sequences


2.5 实验仿真比较

首先分别计算经过和未经过 HP 趋势滤波后特征序列的 HMM 对数似然度。如图 8(a) 所示为 HP 趋势滤波后特征序列的 HMM 对数似然度 (Log-likelihood), 正常事件情况下相对稳定, 使用由训练集对数似然度均值和方差确定的固定阈值能够进行视频异常事件的有效检测; 如 (b) 所示为特征序列未经过 HP 趋势滤波, 直接输入到 HMM 中计算对数似然度。由于光照变化和阴影等干扰因素的存在, 导致不同时刻的对数似然度变化剧烈, 无法用固定阈值对异常事件进行检测, 只能由当前时刻前一段时间内正常事件的对数似然度均值和方差确定检测阈值。

其次比较不同特征提取和检测方案的检测性能。当仅考虑信号的二阶统计特征时, 可以使用 PCA 进行图像特征提取, 进而形成 PCA + HP + HMM 的视频异常事件检测方案。当信号呈非高斯特性时 (如自然场景中复杂的图像), 采用 ICA 进行



(a) 经 HP 滤波后的测试序列在 HMM 下的对数似然度



(b) 未经 HP 滤波的测试序列在 HMM 下的对数似然度

图 8 各图像序列段的对数似然度变化

Fig. 8 The changes of Log-likelihood along the segment of image sequence

特征提取更合适, GMM 相当于状态数为 1 的 HMM, ICA + HP + GMM 视频异常事件检测方案, 仅仅考虑了图像序列中各个图像的自身信息, 而没有考虑图像序列相互之间的关联性。

不同检测方案的检测性能如表 2 所示, 考虑图像的高阶统计特征以及序列的动态特性, 利用 HP 滤波器改善特征稳定性的 ICA + HP + HMM 方案检测性能最佳。

表 2 不同方案的实验结果

Tab. 2 The results of different schemes

各种方案	检测率/%	误检率/%	平均检测时间 / (μ s/段)
ICA + HMM	75.4	6.28	38.1
PCA + HP + HMM	81.94	5.62	39.2
ICA + HP + GMM	87.5	4.19	28.4
ICA + HP + HMM	94.44	2.73	42.8

3 结论

针对室外环境下光照强度变化、阴影和树木遮挡等实际情况, 采用 ICA 和 HP 滤波器对图像进行特征提取, ICA 充分利用了图像的高阶统计特征, HP 滤波有效地保证了特征序列的稳定, 最终有效

改善 HMM 视频异常事件的检测性能。实验结果表明,该算法能够在复杂的室外环境下高效可靠地进行视频异常事件的检测。

参考文献 (References)

- [1] Wang Suyu, Shen Lansun. Intelligent visual surveillance technology: a survey [J]. Journal of Image and Graphics, 2007, 12(9):1505-1514. [王素玉, 沈兰荪. 智能视觉监控技术研究进展 [J]. 中国图象图形学报, 2007, 12(9):1505-1514.]
- [2] Jager M, Knoll C, Hamprecht F A. Weakly supervised learning of a classifier for unusual event detection [J]. IEEE Trans. IP, 2008, 17(2):1700-1708.
- [3] Atray P K, Maddage N C, Kankanhalli M S. Audio based event detection for multimedia surveillance [C] // Proceedings of International Conference on Acoustics, Speech and Signal Processing. Washington DC, USA: IEEE Signal Processing Society, 2006, (5):813-816.
- [4] Hu Zhilan, Jiang Fan, Wang Guijin, et al. Anomaly detection based on motion direction [J]. Acta Automatic Sinica, 2008, 34(11):1348-1357. [胡芝兰, 江帆, 王贵锦, 等. 基于运动方向的异常行为检测 [J]. 自动化学报, 2008, 34(11):1348-1357.]
- [5] Jan T, Piccardi M, Hintz T. Neural network classifiers for automated video surveillance [C]. Proceedings of 2003 IEEE 13th Workshop on Neural Network for Signal Processing, Washington DC, USA: IEEE Signal Processing Society, 2003:729-738.
- [6] Uddin M Z, Lee J J, Kim T S. Independent component feature-based human activity recognition via linear discriminant analysis and hidden Markov model [C] // Proceedings of 30th Annual International IEEE EMBS Conference. Washington DC, USA: IEEE Signal Processing Society, 2008:5168-5171.
- [7] Hurri J, Hyvärinen A, Karhunen J, et al. Image feature extraction using independent component analysis [C] // Proceedings of 1996 IEEE Nordic Signal Processing Symposium. Washington DC, USA: IEEE Signal Processing Society, 1996:475-478.
- [8] Snoek J, Hoey J, Stewart L, et al. Automated detection of unusual events on stairs [J]. Image and Vision Computing, 2009, 27:153-166.
- [9] Jiang F, Wu Y, Katsaggelos A K. A dynamic hierarchical clustering method for trajectory-based unusual video event detection [J]. IEEE Trans. IP, 2009, 18(4):907-913.
- [10] Zhong H, Shi J, Viontai M. Detecting unusual activity in video [C] // Proceedings of IEEE Computer Society Conference Computer Vision and Pattern Recognition. Washington DC, USA: IEEE Computer Society, 2004, (2):819-826.
- [11] Ekkehart S. Estimating the smoothing parameter in the so-called Hodrick-Prescott filter [R]. New England: University of Connecticut, 2004.
- [12] Hyvärinen A, Oja E. A fast fixed-point algorithm for independent component analysis [J]. Neural Computation, 1997, 9(7):1483-1492.
- [13] Kim B G, Park D J. Adaptive image normalisation based on block processing for enhancement of fingerprint image [J]. Electronics Letters, 2002, 38(14):696-698.
- [14] Hyvärinen A, Oja E. Independent component analysis: algorithms and applications [J]. Neural Networks, 2000, 13(4-5):411-430.
- [15] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition [J]. Proceedings of the IEEE, 1989, 77(2):257-286.
- [16] Biem A. A model selection criterion for classification: application to HMM topology optimization [C] // Proceedings of 7th Int. Conf. Document Analysis and Recognition. Washington DC, USA: IEEE Computer Society, 2003:104-108.