

文章编号:1672-058X(2013)05-0030-07

基于改进的 GMM 参数估计的目标检测方法*

李世锋, 文志强, 吴岳忠

(湖南工业大学 计算机与通信学院, 株洲 412007)

摘要:背景减除法通过计算当前帧与背景模型的差来实现运动目标的检测,因此背景建模是背景减除法的关键;混合高斯模型(Gaussian mixture model, GMM)可对存在渐变及重复性运动的场景进行建模,有效的提高了在光线强度变化,物体摇摆等复杂场景下建模的准确性;但它也有其固有缺点,针对利用传统 EM 算法进行 GMM 模型参数估计时,易陷入解空间的局部最优的缺陷,采用基于最大惩罚的 EM 参数估计,对传统的 EM 算法进行改进;另外,在检测不需要满足实时性时,提出了一种基于差分进化算法的 GMM 参数估计法;最后把改进的 GMM 参数估计方法应用于基于 GMM 模型的运动目标检测当中进行验证,并得到很好的检测效果。

关键词:目标检测;GMM;参数估计;EM 算法;差分进化

中图分类号:TP391.41

文献标志码:A

目标检测在实现技术上融合了视频图像处理、人工智能以及模式识别等多个学科,是近年来计算机视觉领域中备受关注的前沿方向。当前目标检测常见的方法有:光流法、帧间差分法及背景减除法等^[1]。光流法在摄像机发生运动的情况下,仍可将独立运动的目标检测出来,但它是采用迭代进行计算,计算过程复杂,对光照、遮挡、阴影等敏感;帧间差分法算法简单,计算复杂度低,实时性好等优点,很好的适应动态环境,特别是当目标运动较快,目标与背景差别明显的时候效果更好,但是由于该方法对光线变化不敏感,在实际检测过程中会出现空洞而不能完整的提取运动目标;背景减除法由于对场景的变化较敏感,所以在检测的过程中需要不断地更新背景。但是,由于 GMM 能利用有限个单高斯模型的加权平均来对视频的像素分布进行描述,因此,它可以用来对光照强度发生渐变,树木因刮风而摇摆等复杂的视频背景进行准确地建模。背景减除法实现目标检测的关键是背景模型的创建与更新,也就是如何才能准确的对 GMM 模型的参数进行估计确定。对参数集进行估计的一般方法有:极大似然估计,期望最大化估计。但在实际处理中,极大似然估计往往由于似然函数的表达式太复杂,而使得参数估计值的求解相当困难,因此常用期望最大化估计(Expectation Maximization Estimation)方法对参数集进行估计。利用 EM 算法能够较好的估计出 GMM 模型参数,但是 EM 算法本质上类似于多元参数空间中的局部爬山算法^[2],在 E 和 M 步骤中,需要隐含地确定每一点的方向和距离。因此,尽管 EM 算法是一种有效的极大似然估计方法,但却容易陷入局部极小值而无法得到最优解,针对这一问题,本文提出了在 EM 算法的 M 步骤中增加似然函数的惩罚项,通过获得最大惩罚值来避免解空间的局部最优;另外,在检测不需要满足实时性时,提出了一种基于差分进化算法的 GMM 参数估计法,来提高利用 GMM 模型进行目标检测的准确性和鲁棒性。

收稿日期:2013-03-05;修回日期:2013-04-06.

* 基金项目:国家自然科学基金资助项目(61170102);湖南省自然科学基金项目(11JJ3070);湖南省科技厅科研基金资助项目(2011TP4004-1);湖南省教育厅科研基金资助项目(11C0398).

作者简介:李世锋(1984-),男,河南濮阳人,硕士研究生,从事计算机视觉、目标跟踪与识别等研究。

1 混合高斯模型基本原理

混合概率模型是由多个独立的概率模型凸组合而成的^[3],它可以用来描述复杂的数据分布,无论该数据分布的结构如何复杂,总可以通过增加成分的方式来描述数据分布的局部特性,因此在视频和图像处理领域是实现目标检测的有效工具。

从广义上来说,混合模型的表达形式如下所示:

$$f(x) = \sum_{k=1}^n \omega_k f_k(x) \quad (1)$$

其中, $f(x)$ 是有 K 个独立成分的混合模型; ω_k 为第 k 个独立成分的权重值,并且满足 $\sum_{k=1}^K \omega_k = 1, \omega_k > 0$; $f_k(x)$ 表示第 k 个独立成分。当 $f(x)$ 的组成成分 $f_k(x)$ 为概率密度函数时,用概率密度函数符号 $p(x)$ 来代替式(1)中的 $f(x)$,由此可得到具有 n 个独立成分的混合概率模型:

$$p(x) = \sum_{k=1}^K \omega_k p_k(x) \quad (2)$$

假设需要处理的视频帧图像的大小为 $M \times N$, 像素集 $X^t = \{x_i^t | i \leq M \times N\}$ 是从 t 时刻的视频帧图像 I_t 中抽取的具有 d 维的样本集。在视频动态对象检测的过程中,由于多种因素的影响,如随着时间 t 的变化,视频背景也可能发生变化,这样,只利用单高斯模型就不能对像素集 X^t 的分布进行有效地描述。但是,可以对单高斯模型进行延伸,即:利用混合高斯模型,即利用 K 个单高斯模型的加权的方式,来对像素集 X^t 的分布进行描述。

若 $\{x_i^t | i \leq M \times N\}$ 的分布近似椭球形状,则第 i 个高斯分布概率密度函数 $\eta(x_i^t, \mu^t, \sum^t)$ 可表示为 $\eta(x_i^t, \mu^t, \sum^t) = \frac{1}{\sqrt{(2\pi)^d} |\sum^t|} \exp\left\{-\frac{1}{2}(x_i^t - \mu^t)^T \frac{1}{\sum^t} (x_i^t - \mu^t)\right\}$, 其中, μ^t 是 t 时刻的样本集的均值; \sum^t 为 t 时刻的样本集的协方差矩阵, $\sum^t = (\sigma_k^t)^2 I$ (σ_k^t 表示标准差, I 表示单位矩阵)。若像素样本之间相互独立,那么 $X^t = \{x_i^t | i \leq M \times N\}$ 发生的概率密度: $p(x_i^t, \mu^t, \sum^t) = \prod_{i=1}^{M \times N} \eta(x_i^t, \mu^t, \sum^t)$, 其中, 像素样本集 X^t 的均值 μ^t 和协方差 \sum^t 可用如下公式计算得到: $\hat{\mu}^t = \frac{1}{M \times N} \sum_{i=1}^{M \times N} x_i^t$

$$\sum^t = \begin{pmatrix} \sigma_{11}^t & \cdots & \sigma_{1N}^t \\ \vdots & \cdots & \vdots \\ \sigma_{M1}^t & \cdots & \sigma_{MN}^t \end{pmatrix} = E[(X^t - \hat{\mu}^t)(X^t - \hat{\mu}^t)^T] = \frac{1}{M \times N} \sum_{i=1}^{M \times N} (X^t - \hat{\mu}^t)(X^t - \hat{\mu}^t)^T \quad (3)$$

若式(2)中的独立成分满足高斯分布,则该混合模型就是混合高斯模型。结合公式(2)、式(3)可得混合高斯模型的表达式:

$$\begin{aligned} p(x_i^t | \theta^t) &= \sum_{k=1}^K \omega_k^t p_k(x_i^t | \theta_k^t) = \sum_{k=1}^K \omega_k^t \eta(x_i^t, \mu_k^t, \sum_k^t) \\ &= \sum_{k=1}^K \omega_k^t \left[\frac{1}{\sqrt{(2\pi)^d} |\sum_k^t|} \exp\left\{-\frac{1}{2}(x_i^t - \mu_k^t)^T \frac{1}{\sum_k^t} (x_i^t - \mu_k^t)\right\} \right] \end{aligned} \quad (4)$$

其中, 参数集 $\theta^t = \{\omega_k^t, \mu_k^t, \sum_k^t\}_{k=1}^K$ 中的 $\omega_k^t, \mu_k^t, \sum_k^t$ 分别为 t 时刻第 k 个成分的权重值、样本均值及协方差矩阵, 并且满足 $\sum_{k=1}^K \omega_k^t = 1, \omega_k^t > 0$ 。如果视频帧 I_t 中像素的 RGB 色彩空间值彼此独立, 且具有相同的方差 σ_k^t , 则由式(3)可得:

$$\sum_k^t = (\sigma_k^t)^2 I = (\sigma_k^t)^2 \begin{pmatrix} 1 & \cdots & 0 \\ \vdots & \cdots & \vdots \\ 0 & \cdots & 1 \end{pmatrix} \quad k = 1, 2, \dots, K$$

因此,式(4)可化简:

$$p(x_i^t | \theta^t) = \sum_{k=1}^K \omega_k^t \left[\frac{\sigma_k^t}{\sqrt{(2\pi)^d}} \exp \left\{ -\frac{1}{2(\sigma_k^t)^2} (x_i^t - \mu_k^t)^T (x_i^t - \mu_k^t) \right\} \right]$$

2 GMM 模型的参数估计

根据视频帧 I_t 的像素集 $X^t = \{x_i^t | i \leq M \times N\}$, 如何对模型中的参数集 $\theta^t = \{\omega_k^t, \mu_k^t, \sum_{k=1}^t \}_{k=1}^K$ 进行有效估计, 在利用混合高斯模型对运动目标进行检测的方法中具有重要意义。对参数集 θ^t 进行估计的一般方法有: 极大似然估计, 期望最大化估计。但在实际处理中, 极大似然估计往往由于似然函数的表达式太复杂, 而使得参数估计值 $\hat{\theta}^t$ 的求解相当困难^[5], 因此常用期望最大化估计 (Expectation Maximization Estimation) 方法对参数集 θ^t 进行估计。

2.1 期望最大化估计

本章所说的 EM 算法是通过相应的像素数据, 对混合高斯模型的参数进行极大似然估计的方法。当视频图像 I_t 中的像素数据包含噪声或部分缺失时, EM 算法可以通过迭代来给出参数集 θ^t 的当前估计值^[6]。每个迭代分为两个步骤, 具体 EM 算法如下:

EM 算法:

(1) 将 t 时刻的视频帧划分相应的 K 个区域, 初始化参数集 $\theta^t = \{\omega_k^t, \mu_k^t, \sum_{k=1}^t \}_{k=1}^K$

(2) E-step: 计算 $P_{ik}^t = \omega_k^t P_k(x_i^t | \theta_k^t)$,

$$P_{ik}^t = \frac{\omega_k^t P_k(x_i^t | \theta_k^t)}{p(x_i^t | \theta_k^t)} = \frac{\omega_k^t P_k(x_i^t | \theta_k^t)}{\sum_{k=1}^K \omega_k^t P_k(x_i^t | \theta_k^t)} \quad (5)$$

(3) M-step: 迭代计算 $\hat{\omega}_k^t, \hat{\mu}_k^t, \sum_{k=1}^t$:

$$\hat{\omega}_k^t = \frac{1}{M \times N} \sum_{i=1}^K \frac{\omega_k^t P_k(x_i^t | \theta_k^t)}{\sum_{k=1}^n \omega_k^t P_k(x_i^t | \theta_k^t)} = \frac{\sum_{i=1}^{M \times N} P_{ik}^t}{M \times N} \quad (6)$$

$$\hat{\mu}_k^t = \frac{\sum_{i=1}^{M \times N} P_{ik}^t x_i^t}{\sum_{i=1}^{M \times N} P_{ik}^t} = \frac{\sum_{i=1}^{M \times N} P_{ik}^t x_i^t}{(M \times N) \hat{\omega}_k^t} \quad (7)$$

$$\sum_{k=1}^t \hat{\omega}_k^t = \frac{\sum_{i=1}^{M \times N} P_{ik}^t (x_i^t - \hat{\mu}_k^t) (x_i^t - \hat{\mu}_k^t)^T}{(M \times N) \hat{\omega}_k^t} \quad (8)$$

(4) if 迭代未收敛, 则转到 E-step;

(5) until 迭代收敛;

(6) return 像素 x_i^t 属于第 k 个区域的后验概率 P_{ik}^t ;

利用式(5)~(8)进行迭代, 当迭代收敛时, 便可确定像素 x_i^t 属于第 k 个区域的后验概率 P_{ik}^t 。

2.2 基于最大惩罚的参数估计

EM 算法能有效地对混合高斯模型参数进行估计, 但容易出现解空间的局部最优的问题^[7]。本节针对传统的 EM 算法进行改进, 即: 采用逆 Wishart 先验作为似然函数的惩罚项, 用来避免解空间的局部最优解。从本质上看, 最大惩罚似然估计实际上是基于贝叶斯方法的最大后验参数估计, 其表达式:

$$\hat{\theta}^t = \arg \max_{\theta} \{ \ln P(X^t | \theta^t) + \ln P(\theta^t) \} =$$

$$\begin{aligned} & \arg \max_{\theta} \left\{ \sum_{i=1}^{M \times N} \ln \sum_{k=1}^K \omega_k^i p_k(x_i^t | \theta_k^t) + \ln P(\theta^t) \right\} = \\ & \arg \max_{\theta} \left\{ \sum_{i=1}^{M \times N} \ln \sum_{k=1}^K \omega_k^i \left[\frac{1}{\sqrt{(2\pi)^d} \left| \sum_k^t \right|} \exp \left\{ -\frac{1}{2} (x_i^t - \mu_k^t)^T \frac{1}{\sum_k^t} (x_i^t - \mu_k^t) \right\} \right] + \ln P(\theta^t) \right\} \end{aligned} \quad (9)$$

其中相关参数的先验假如下各式:

$$\begin{aligned} P(\theta^t) &= D(\omega^t | \gamma^t) \prod_{k=1}^K P(\mu_k, \sum_k) = \\ & D(\omega^t | \gamma^t) \prod_{k=1}^K \eta(\mu_k^t | \nu_k^t, \frac{1}{\varepsilon_k^t} \sum_k^t) W_i(\frac{1}{\sum_k^t} | \delta_k^t, \beta_k^t) \end{aligned} \quad (10)$$

其中:

$$D(\omega^t | \gamma^t) = b(\gamma^t) \prod_{k=1}^K (\omega_k^t)^{\gamma_k - 1} \quad (11)$$

$$\eta(\mu_k^t | \nu_k^t, \frac{1}{\varepsilon_k^t} \sum_k^t) = (2\pi)^{-\frac{d}{2}} \left| \nu_k^t \cdot \frac{1}{\varepsilon_k^t} \sum_k^t \right|^{\frac{1}{2}} \exp \left\{ -\frac{\varepsilon_k^t}{2} (\mu_k^t - \nu_k^t)^T \frac{1}{\sum_k^t} (\mu_k^t - \nu_k^t) \right\} \quad (12)$$

$$W_i(\frac{1}{\sum_k^t} | \delta_k^t, \beta_k^t) = c(\delta_k^t, \beta_k^t) \left| \frac{1}{\sum_k^t} \right|^{\delta_k^t - \frac{(d+1)}{2}} \exp \left\{ -tr(\beta_k^t \frac{1}{\sum_k^t}) \right\} \quad (13)$$

其中, d 表示像素的维数; $\delta_k^t - \frac{(d+1)}{2}$, $b(\gamma^t)$, $c(\delta_k^t, \beta_k^t)$ 是标准化因子; $\gamma_k^t, \varepsilon_k^t, \nu_k^t, \delta_k^t$ 都是常数向量; β_k^t 为常数矩阵; $tr(\cdot)$ 是迹运算。把式(10)、(11)、(12)及(13)代入式(9), 可得:

$$\begin{aligned} \hat{\theta}_{map} &= \arg \max_{\theta} \left\{ \sum_{i=1}^{M \times N} \ln \sum_{k=1}^K \omega_k^i \left[\frac{1}{\sqrt{(2\pi)^d} \left| \sum_k^t \right|} \exp \left\{ -\frac{1}{2} (x_i^t - \mu_k^t)^T \frac{1}{\sum_k^t} (x_i^t - \mu_k^t) \right\} \right] \right\} \\ &+ \ln D(\omega^t | \gamma^t) + \sum_{j=1}^k \left[\ln \eta(\mu_k^t | \nu_k^t, \frac{1}{\varepsilon_k^t} \sum_k^t) W_i(\frac{1}{\sum_k^t} | \delta_k^t, \beta_k^t) \right] \end{aligned} \quad (14)$$

2.3 基于差分进化的参数估计

EM 算法本质上类似于多元参数空间中的局部爬山算法^[8], 需要隐含地确定每一点的方向和距离。因此, 尽管 EM 算法是一种有效的极大似然估计方法, 但却容易陷入局部极小值而无法得到最优解, 同时, 其对初始值也十分敏感。为解决上述问题, 上一节引进逆 Wishart 先验作为似然函数惩罚项的方法对传统 EM 算法进行改进, 本节对不需要满足实时性的目标检测的情况, 引进差分进化算法 (Differential Evolution Algorithm, DE) 用于对 GMM 的参数进行估计。

差分进化算法 (DE) 是由 Rainer Storn 和 Kenneth Price 提出的一种用于优化问题的启发式算法^[9]。本质上说, 它是一种基于实数编码的具有择优思想的贪婪遗传算法^[10]。其原理为对种群进行初始化, 并对当代种群中的个体进行相应的变异和交叉操作, 由此形成一个对应的临时种群; 之后, 按照贪婪算法原则, 对父代种群中的个体和临时种群中的个体, 采用一对一的淘汰机制来更新种群, 从而使适应性更强的个体组成新一代种群。依此重复, 让种群一直进化下去, 直到满足要求。基于差分进化算法的 GMM 参数估计的具体流程如图 1 所示。

3 基于 GMM 的运动目标检测

根据上面所讲内容, 如果要对视频中第 t 帧的目标进行检测, 能够利用相应的 GMM 参数估计方法, 获得该帧的最优模型参数集 $\{\omega_k^t, \mu_k^t, \sum_k^t\}_{k=1}^K$, 然后根据式(15) 判断像素 x_i 属于哪一个高斯成员, 进而实现对目标的检测:

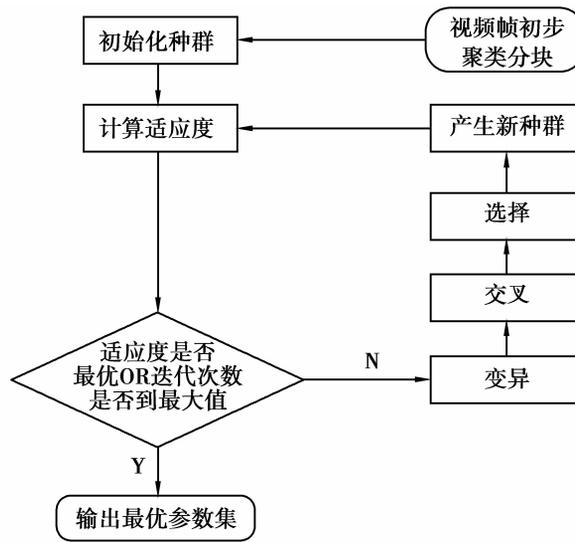


图 1 基于差分进化的 GMM 参数估计流程图

$$Cluster(x_i) = \operatorname{argmax}_k \omega_k^t p(x_i | \mu_k^t, \sum_k^t) \quad k = 1, 2, \dots, K \quad (15)$$

视频帧序列 $\{f(x_t, y_t) | t = 1, 2, 3, \dots\}$ 中,可使用由 K 个成分组成的 GMM 来对每帧中的像素样本点进行建模,即:

$$p(x_i^t | \theta^t) = \sum_{k=1}^K \omega_k^t p_k(x_i^t | \theta^t) = \sum_{k=1}^K \omega_k^t \eta(x_i^t, \mu_k^t, \sum_k^t) \quad (16)$$

若要实现目标检测,首先要估计出视频中第 t 帧的参数集 $\{\omega_k^t, \mu_k^t, \sum_k^t\}_{k=1}^K$,接着对 GMM 中的 K 个成员,按照 ω_k^t / σ_k^t 的值由大到小进行排序的方式来确定优先级^[7],然后输入视频中第 $t + 1$ 帧,将 x_{t+1} 的像素值 $I(x_{t+1})$ 与第 t 时刻 K 个高斯成员的均值 μ_k^t 分别进行比较,并按照下式进行判断:

$$|I(x_{t+1}) - \mu_k^t| \leq \lambda \sigma_k^t, 1 \leq k \leq K$$

其中 λ 为常数; σ_k^t 为第 k 个成员的标准差,若上式成立,则表明 x_{t+1} 与第 k 个高斯成员匹配,并按下列公式更新第 k 个高斯成员的所有参数:

$$\begin{aligned} \rho &= \gamma \cdot \eta(x_{t+1} | \mu_k^t, \sum_k^t) \\ \omega_k^{t+1} &= (1 - \gamma) \cdot \omega_k^t + \gamma \cdot M_k^t \\ \mu_k^{t+1} &= (1 - \rho) \cdot \mu_k^t + \rho \cdot x_{t+1} \\ (\sigma_k^{t+1})^2 &= (1 - \rho) \cdot (\sigma_k^t)^2 + \rho \cdot (x_{t+1} - \mu_k^{t+1})^T (x_{t+1} - \mu_k^{t+1}) \end{aligned}$$

其中, γ 表示学习速率; ρ 表示参数的更新速率;匹配成功时 $M_k^t = 1$, (此时第 k 个高斯分布在背景模型中的权重增大), 否则 $M_k^t = 0$ (对应的高斯分布在背景模型中的权重减小); 其他不匹配的 $k - 1$ 个高斯成员按式(16)更新其权值, 其他的值不变。若不存在匹配的高斯成员, 则用一个高方差、低权值且均值为 $I(x_{t+1})$ 的新高斯分布取代原来的最后一个高斯成员, 即第 K 个高斯成员。最后, 将更新参数后的 K 个成员, 按 $\omega_k^{t+1} / \sigma_k^{t+1}$ 的值从大到小进行排序。相对来说, 由于背景在视频帧序列中比较稳定, 即权重较大且方差较小的分布可判断为背景, 否则判断为前景, 即运动目标。

背景模型从排序后的前 m 个高斯成员中选择 $m = \operatorname{argmin}_l (\sum_{k=1}^l \omega_k^{t+1} > T)$, 被选中的 m 个高斯成员作为背景模型, 所以其他剩余的 $K - m$ 个高斯成员作为前景, 也就是运动目标, 进而实现运动目标的检测。

4 实验仿真与结果分析

4.1 GMM 参数估计的实验仿真

为了验证前面所提出的几种 GMM 模型参数估计方法的效果,将用均值分别 58、126、170、187 及方差对应为 2、4、3、1 的 4 小组正态的数据,等比例混合而成的数据集进行实验,实验结果如表 3 所示,从表 3 可知,基于最大惩罚 EM 算法的模型参数估计效果最好,基于差分进化算法的次之。

表 3 GMM 参数估计效果比较

$P \setminus A$	传统 EM 算法	基于惩罚的 EM 算法	基于差分进化的算法
μ_k	57.94, 125.81, 169.85, 187.08	57.98, 125.97, 169.99, 187.02	58.37, 125.91, 170.33, 187.01
σ_k^2	4.168, 15.721, 9.793, 1.385	4.063, 16.195, 8.9014, 1.0159	3.952, 16.851, 9.343, 1.169
ω_k	0.29, 0.26, 0.21, 0.24	0.25, 0.25, 0.25, 0.25	0.246, 0.250, 0.250, 0.254

4.2 目标检测实验仿真

这里使用自拍视频的第 135 帧来验证基于 GMM 的视频帧检测效果,实验结果如图 2 所示,从视频中抽取一帧,采用混合高斯模型并结合目标的时间空间属性,对抽取的视频帧进行提取检测,实验结果如图 3 所示。

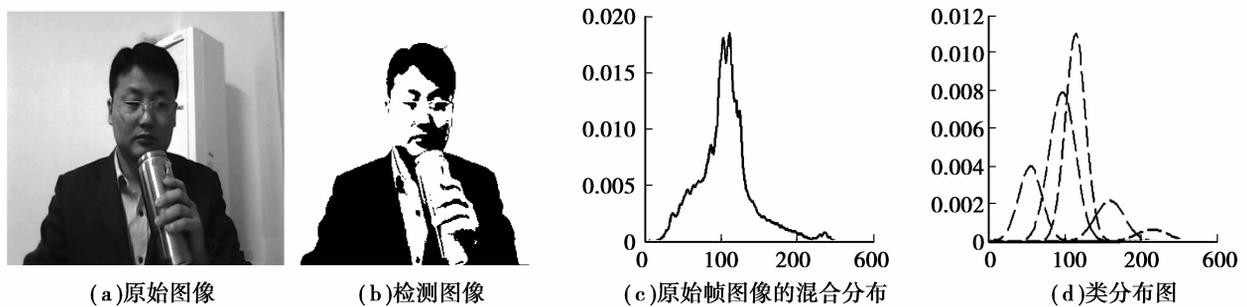


图 2 图像分割效果及其相关属性

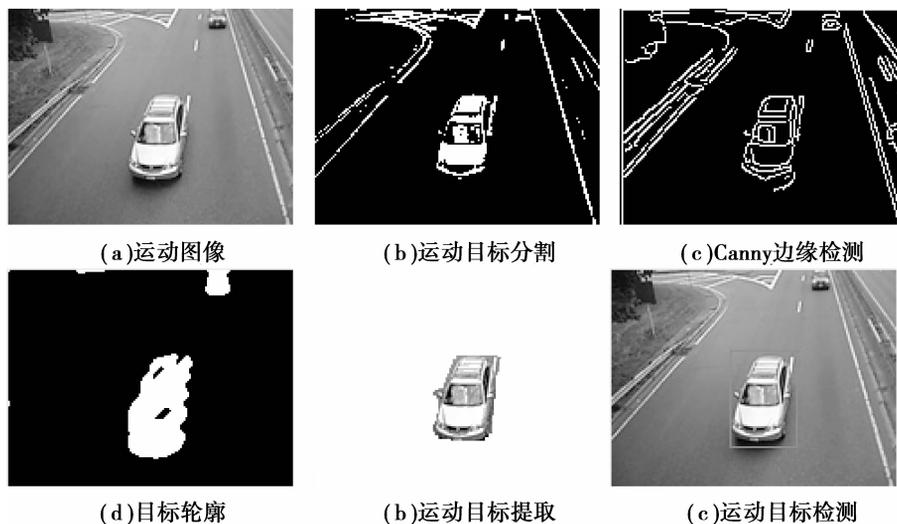


图 3 小汽车运动目标的分割与提取

5 结 束

本文对混合高斯模型的参数估计进行了研究,即针对利用传统 EM 算法进行 GMM 模型参数估计时,易陷入解空间的局部最优的缺陷,本文采用基于最大惩罚的 EM 参数估计,对传统 EM 算法进行了改进;另外,当实时性要求不严格时,提出了一种基于差分进化算法的 GMM 参数估计法;最后把改进的 GMM 参数估计方法应用于基于 GMM 模型的运动目标检测当中进行验证。实验表明,本文所提出的模型参数估计方法及运动目标检测算法的效果非常好。

参考文献:

- [1] TSAO T, WEN Z Q. Image-based target tracking through rapid sensor orientation change[J]. Optical Engineering, 2008, 41(3): 697-703
- [2] JIAN B, BABA C, Vemuri. Robust Point Set Registration Using Gaussian Mixture Models[J]. PAMI, 2011, 33(8): 1633-1645
- [3] CHEN L H, LAI Y C, LIAO H Y. Movie scene segmentation using background information[J]. Pattern Recognition, 2008, 41: 1056-1065
- [4] SONG X H, CHEN J Z. A Robust Moving Objects Detection Based on Improved Gaussian Mixture Model[C]. AICI, 2010
- [5] STAUFFER C, GRIMSON W. Learning patterns of activity using real-time tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 747-757
- [6] ZIVKOVIC Z, VAN F. Efficient adaptive density estimation per image pixel for the task of background subtraction[J]. Pattern Recognition Letters, 2006, 27(7): 773-780
- [7] LEE DS. Effective Gaussian mixture learning for video background subtraction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(5): 827-832
- [8] SERGIOS T. Pattern Recognition[M]. (Fourth Edition) Academic Press, 2009
- [9] GRAY B, ADRIAN K. Learning OpenCV[M]. 于仕琪, 刘瑞祯译. 清华大学出版社, 2009
- [10] HIDENORI W, SHOGO M. Interval calculation of EM algorithm for GMM parameter estimation[C]. ISCAS, 2010: 2686-2689.

Target Detection Method Based on Improved GMM Parameter Estimation

LI Shi-feng, WEN Zhi-qiang, WU Yue-zhong

(School of Computer and Communication, Hunan University of Technology, Hunan Zhuzhou 412007, China)

Abstract: Background subtraction method through calculating the difference between the current frame and the background model achieves the detection of moving targets, so the background modeling is a key to the method. Gaussian mixture model can model on the existence of a gradient and repetitive motion scene and effectively improve the accuracy of the modeling under the complex scenes of the light intensity changes and objects swing. But it also has its inherent drawbacks. In this paper, for the defect of easy to fall into the local optimum of the solution space when using traditional EM algorithm to estimate GMM parameters, we use EM parameter estimation based on the the maximum punishment to improve traditional algorithm; in addition, we advance a differential evolution algorithm based GMM parameter estimation method when the real-time does not need in the detection; finally, we put the improved GMM parameter estimation method to test the moving target detection based on GMM model and get a good result.

Key words: object detection; GMM; parameter estimation; EM algorithm; differential evolution