

中图法分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2011)01-0037-07

论文索引信息: 蒋鹏, 秦小麟. 复杂背景下的自适应前景分割算法 [J]. 中国图象图形学报, 2011, 16(1): 37-43

复杂背景下的自适应前景分割算法

蒋鹏, 秦小麟

(南京航空航天大学计算机科学与工程系, 南京 210016)

摘要: 复杂背景下的运动前景分割是计算机视觉领域研究的一个重点研究问题。为了对复杂背景下的运动前景进行有效分割, 提出了一种复杂背景下自适应前景分割算法。该算法的背景模型是由一系列聚类和聚类的权重构成。每个聚类表示背景的一个历史状态, 并能够根据背景的变化, 自适应创建、更新或删除聚类, 使得背景模型能够准确反映出场景的变化。每个聚类权重是根据聚类的大小和更新时间自动确定的。为了自动确定该方法的重要阈值, 还提出一种基于非参数密度估计的阈值估计方法, 并在不同的场景下与多个背景建模方法进行了比较, 实验结果表明, 该算法是有效的。

关键词: 背景差; 核密度; 阈值估计

Robust foreground detection with adaptive threshold estimation

Jiang Peng, Qin Xiaolin

(Department of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016 China)

Abstract: A robust background subtraction technique is proposed based on adaptive clustering of temporal color/intensity. An un-supervised clustering method is proposed to model a background with a group of weighted clusters. The clusters and their weights can be updated with a background change. In addition, the unimodal or multimodal distributions of background are detected adaptively. We also present a novel statistical threshold estimation scheme to determine the thresholds using in our method. Experimental results on different types of videos demonstrate the utility and performance of the proposed approach.

Keywords: background subtraction; kernel density estimation; statistical threshold estimation

0 引言

复杂背景下如何有效地对运动前景进行分割是目前研究的一个重点问题。这是因为在实际场景中, 背景可能不是完全静止的, 例如背景中可能包含有摆动的树叶或者变化的光照等。因此在复杂背景下直接使用传统的背景差法效果不佳。

近年来, 出现了大量的研究^[1-3] 尝试解决复杂背景下的前景分割问题。其中高斯混合模型

(GMM)^[4-6] 和非参数模型^[7] 是目前较为典型的背景建模方法。GMM 模型是用一个高斯成分对应场景中的一个状态。早期的 GMM 方法通常采用固定个数的高斯成分数^[4]。但由于各个像素点变化的频繁程度是不同的, 需要根据变化频率自适应地确定高斯成分数, 才能正确的反映这种变化, 为此 Lee 等人提出了根据场景变化自适应确定高斯成分数的方法^[5-6]。其中文献[6]的自适应高斯混合模型 (AGMM) 方法比较有代表性。该方法通过极大似然估计估算出优化的高斯成分数。GMM 和 AGMM

收稿日期: 2009-05-11; 修回日期: 2009-09-08

基金项目: 国家自然科学基金项目(60673127); 国家高技术研究发展计划(863)项目(2007AA01Z404)。

第一作者简介: 蒋鹏(1976—), 男, 南京航空航天大学计算机应用专业博士研究生, 主要研究方向为多媒体数据库和计算机视觉。E-mail: jpplus@163.com。

均假设背景每个状态都是符合高斯分布的,然而这种假设并不一定成立。Elgammal 等人提出了一种非参数背景建模算法——核密度估计(KDE)^[7]。该方法是利用核密度估计获得像素的密度分布,其获得的背景模型较为准确,且检测效果优于混合高斯模型算法。

但是过去的 GMM 和 KDE 等方法的背景模型大多是基于历史样本分布的,需要存储大量的历史数据,内存消耗很大,而且在背景更新时,也往往需要所有历史数据都要参与更新,因此速度较慢。另外,前景的出现还会对背景模型产生干扰。例如在 AGMM 方法中,前景的颜色是通过增加新的高斯成分融入到背景模型获得的,而且在 KDE 方法中,前景颜色也参与了密度估计。这样当前景运动缓慢或者有大面积前景出现时,会产生前景和背景的混合现象。

为了解决传统的多模方法内存消耗大,前景背景容易混合等问题,本文提出了一种复杂背景下利用自适应聚类来对背景进行建模的方法。该方法的背景模型是由一个或多个聚类以及聚类的权重构成。该方法能够根据场景的变化情况自适应地对聚类进行增加、修改和删除操作,使得背景模型能够反映出场景真实的变化情况。同时,本文方法是用聚类权重通过淘汰过期聚类的方法来解决前景干扰问题,而将过期的聚类进行删除则可以保持背景模型的准确性和及时性。为了提高分割精度,本文还提出了一种新的基于核密度估计的自适应阈值检测方法,该方法能够根据不同的噪声和光照变化情况自适应确定阈值。

1 时间域自适应背景模型

由于过去的多模方法往往需要保存历史像素值,以实现背景模型的建立和更新,因此需要耗费大量的内存。为了解决该问题,本文提出了一种利用聚类来对历史像素值进行在线归类的方法。与以往方法不同的是,本文的背景模型是先利用一系列聚类来表示背景的各个状态;然后随着背景的改变,通过创建、修改和删除聚类来反映背景的变化。当背景初始化完毕以后,则从一个背景状态开始,如果颜色与已有背景状态不相似,则创建一个新的状态;如果颜色与已有状态相似,则将颜色更新到已有状态中;而当状态长期未得到更新时,则会动态地删除该

状态。这样,每个点处的背景模型总是利用这 3 个过程不断地进行更新。由于每个聚类仅保持该聚类元素的均值,因此无需保留历史值,这样就可以减少内存使用量。

本文将任意点 $p = (x, y)$ 处的像素值记为 $I(x, y)$,任意点 p 处的聚类总数记为 N_p ,该点处第 i 个聚类表示为 C_i ,将类 C_i 的聚类中心像素值记为 $v_i(x, y)$,任意点 p 第 i 个聚类 C_i 包含的元素个数记为 $N_{C_i}^p$ 。

聚类前,首先进行初始化操作。背景初始化过程就是提取一帧图像帧,并将聚类数设置成一个,即 N_p 为 1,将聚类中心设置成当前图像帧的像素值 $v_0(x, y)$ 。在初始化完毕以后,进入模型在线更新阶段,包括创建、更新和删除背景状态。

对于每一个待检测图像帧,首先计算任意点 p 的像素值 $I(x, y)$ 与各个聚类中心的像素值差,即

$$D_{i,p} = |I(x, y) - v_i(x, y)| \quad 0 < i < N_{C_i}^p \quad (1)$$

并求出所有差值中的最小值 $D_{i,p}^{\min}$,然后判断 $D_{i,p}^{\min}$ 是否满足下式:

$$D_{i,p}^{\min} > \alpha \quad (2)$$

其中 α 为一个重要参数,其设置将在第 3 节讨论。当满足式(2),则表明任意点 p 的像素值 $I(x, y)$ 与所有的聚类都不相似,即任意点 p 的像素值 $I(x, y)$ 无法用现有的背景状态表示,因此需要创建一个新的聚类来记录任意点 p 的像素值 $I(x, y)$ 。

创建新类的过程如下:设创建的一个新类为第 m 个类 C_m ,创建状态就是用类 C_m 来记录任意点 p 的像素值 $I(x, y)$,并相应更新聚类的总数以及聚类元素的个数。创建步骤如下式

$$\begin{aligned} v_m(x, y) &= I(x, y) \\ N_{C_m}^p &= N_{C_m}^p + 1 \\ N_p &= 1 \end{aligned} \quad (3)$$

当不满足式(2)时,则表示能够在现有的聚类中找到与任意点 p 处的像素值 $I(x, y)$ 相近的聚类,因此将任意点 p 处的像素值 $I(x, y)$ 更新到最相近的聚类。用式(1)求出任意点 p 的像素值 $I(x, y)$ 到所有聚类中最近距离的聚类,将该聚类记为 C_k ,用下式更新聚类 C_k 的聚类中心:

$$v_k(x, y) = \frac{N_{C_k}^p \times v_k(x, y) + I(x, y)}{N_{C_k}^p + 1} \quad (4)$$

$$N_p = N_p + 1$$

式(4)实际上是将计算得到的历史值和任意点 p 的

像素值 $I(x, y)$ 的均值作为聚类的均值。这样的好处是当有光照缓慢变化时,聚类中心可以自动地向匹配次数较多的颜色集中,因此可以有效地避免光照缓慢变化对背景的影响。

在创建和更新聚类以后,聚类的权重值也需要进行更新。聚类的权重值是表示一个聚类在背景模型中的重要性。权重值受以下几个因素的影响:1)聚类包含的元素个数,当一个聚类包含的元素个数越多,表示该聚类代表的颜色出现的概率大,权重值也相应较高;2)聚类更新时间,如果一个聚类长期没有得到更新,则可能是静止的前景造成的,其权重值较小。因此本文方法用一个计数器来记录每个类最近被更新的时间。并用任意点 p 该计数器的更新时间值与当前时间的差值 Δp 来记录该聚类未被更新的时间。

设 w_{c_j} 代表第 j 个聚类 C_j 的权重,定义为

$$w_{c_j} = \frac{w_{c_j}^N + w_{c_j}^t}{2} \quad (5)$$

式中, $w_{c_j}^N$ 为每个聚类大小权重值,包含元素越多的聚类,其权重也就越大。 $w_{c_j}^N$ 定义为

$$w_{c_j}^N = \frac{N_{c_j}^p}{\sum_{i=1}^{N_p} N_{c_i}^p} \quad (6)$$

$w_{c_j}^t$ 为每个聚类的时间域权重,本文定义为

$$w_{c_j}^t = \exp\left(-\frac{(Tp)^2}{(N_{c_j}^p)^2}\right) \quad (7)$$

式中 $w_{c_j}^t$ 受以下两个因素影响:1)如果一个聚类未被更新的时间越长,则权重值越小;2)若聚类包含的元素越多,则该聚类衰退的速度越慢。

随着光照的变化和前景的出现,越来越多的聚类会被创建。由于保留所有的聚类不仅需要消耗大量的内存,而且过期的聚类会污染背景,因此会引入不必要的计算量和影响前景分割的效果。为此本文提出了一种根据聚类权重值来淘汰过期状态的方法。当 $w_{c_j}^t$ 过小时,则认为该聚类已经过期,即将该聚类删除。

$$w_{c_j} < \eta \quad (8)$$

其中 η 为一个常数,是用于判断聚类是否过期的的重要参数,本文将在第3节给出一种自动设置方法。在删除过期的聚类后,聚类数减一。

由于前景是在运动,因此由前景构成的聚类常

常包含的元素少,而且长时间未被更新。通过本文方法可以检测出前景聚类,并可将其删除,这样就可以有效地避免前景对背景的污染。

当背景变化较小时,像素点会被更新到已有聚类中,聚类数较少;而当背景变化较大时,则会通过创建新类来保留背景的状态,聚类数也相应较多。如果将每个点所处位置的聚类数用颜色的深浅来描述的话,则可以形成一个背景状态分布图。亮度越大的区域,表示其聚类数越多。

图1为以 Vssn06 (video 7) 为例的背景状态分布图。其中图1(a)为背景,图1(b)一(d)分别为第250帧、400帧、500帧的背景状态分布图。该场景为一个典型的户外场景,图像上方的树叶被风吹过,有细微的位移。从图1(b)一(d)可以看出,在树叶处,其背景变化较大,因此聚类数也相应较多,在图中显示颜色较亮。其他区域,例如马路,背景几乎不变,本文获得的聚类数很小,在图中显示的颜色则较暗。从图1中可以看出,本文算法可以有效地根据背景变化自适应确定背景的聚类数。这样动态决定聚类数的好处是无需对场景中的路面或车辆等静态区域分配多个状态,因此可以有效地减少计算量和内存使用量。在400帧附近,有运动前景出现。另外从图1(c)可见,前景的出现造成了聚类数的增加。但当前景移开以后,被前景遮盖的区域会重新被背景点所更新,因此由前景点构成的聚类权重值较少。利用本文的删除步骤即将前景的聚类删除。从图1(d)可见,聚类数并未因前景的出现而增

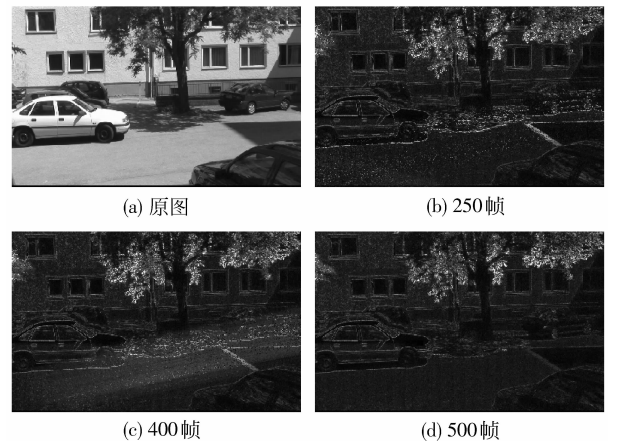


图1 Vssn06 video7 背景模态分布图

Fig. 1 Background modal number distribution map of Vssn06 video7

加,背景模型也未因前景的出现而受到影响。由此可见,通过增加、修改和删除背景状态,本文提出的背景模型能够反映出真实背景的变化。

2 快速前景检测

由于本文的背景模型是用一个或者多个聚类来表示像素的历史值,因此可以根据历史值信息来计算待检测点属于背景的概率。本文采用非参数密度估计来进行密度估计。非参数密度估计是一种利用历史分布来估计样本密度的方法,文献[7]最早将该方法用于前景检测。与文献[7]等方法不同,由于本文已经采用聚类方法对历史值进行了归类,因此可以利用聚类信息来直接进行密度估计。如果采用高斯函数作为核函数的话,则待检测像素的像素值 $I(x,y)$ 属于背景的概率 $p(I(x,y))$ 定义为

$$p(I(x,y)) = \sum_{j=1}^{N_p} \frac{w_j}{\sigma \sqrt{2\pi}} \exp\left(-\frac{(I(x,y) - v_j(x,y))^2}{2\sigma^2}\right) \quad (9)$$

式中, σ 为高斯核函数的带宽,用文献[8]的优化带宽方法获得。

与文献[7]的核密度估计方法相比,本文基于背景聚类的核密度估计方法的好处有以下两个: 1) 本文方法是用聚类中心来表示每个聚类的各个历史均值,这样仅用少数几个聚类就可以表示所有的历史数据,而文献[7]则是用历史像素值来估计密度,与文献[7]方法相比,由于本文方法处理的数据量很小,因此可以大大减少计算量; 2) 本文方法中,式(9)的计算量是根据聚类数的多少来决定的,可以根据背景的变化程度来优化分配计算资源。例如当背景几乎不变时, $N_p = 1$, 一次查表操作就可以获得概率值 $p(I(x,y))$, 计算量很小。

在获得检测像素的像素值 $I(x,y)$ 属于背景的概率值 $p(I(x,y))$ 之后,一个简单的前景分割方法就是比较 $p(I(x,y))$ 和一个阈值 β , 当 $p(I(x,y))$ 满足

$$p(I(x,y)) < \beta \quad (10)$$

时,则为前景,否则为背景。 β 的设置通常需要有场景的先验知识。不同的场景一般需人工干预才能获得优化的阈值。为了减少阈值设置的随意性,本文给出了一种优化的 β 自动检测方法。

3 自适应阈值估计

α, β 和 η 是本文用到的参数。其中 α 是判断待检测像素点的像素值是否与历史像素值相似的阈值, β 为前景阈值, η 为聚类删除阈值。由于这 3 个阈值都与视频中的噪声分布以及背景变化程度等因素相关,因此需要根据场景的实际变化情况自适应设置这 3 个阈值。

对图像的颜色分布进行分析是一种常见的阈值分析方法。例如文献[9]用各个像素的颜色来构成颜色直方图,并采用直方图中第 1 个波谷作为优化的前景阈值。但由于这种方法是利用离散的像素值来分析,因此对噪声数据比较敏感。与过去的方法不同,本文是对一幅图像中所有像素的概率值 $p(I(x,y))$ 进行核密度估计,以获得概率分布特性。由于核密度估计是利用核函数进行加权计算平均中心值,因此可以获得连续和平滑的密度分布。这种核密度估计方法相当于对概率直方图进行了平滑处理,可以有效地避免噪声数据的干扰。为了便于分析,本文对 KDE 图用相邻的 3 个值的均值作为当前值的方法来进行进一步平滑处理。图 2 为以 Highway-前 40 帧作为参考背景的核密度分布图,其中 X 轴为像素差值, Y 轴为密度值。从图 2 可以看出,概率值 $p(I(x,y))$ 的分布具有两个峰值,其中一个峰值在概率值的零值附近。由于概率值很小,表示与颜色背景的差异很大,因此可以判断这个波峰是由前景点形成的。随着概率值的增加,概率的密度值快速下降,到转折点 T_a 处,密度值为一个波谷。




图 2 像素概率核密度图

Fig. 2 The example KDE curve of the possibility of the pixels belong to background model

由于前景的概率值均小于 T_a 值,因此可以利用这个波谷的概率值 T_a 作为前景阈值。当概率值大于 T_a 时,又出现第 2 个波峰,波峰处的概率值记为 T_b 。由于 T_b 附近的概率值均较大,表示所代表的点与背景模型较为匹配,因此可以判断该峰值为背景像素点形成的。由于核密度是对中心点进行了加权,因此可以将 T_b 看成是背景点概率值的均值。背景点的概率值往往受摄像机噪声的影响,当摄像机产生的噪声较多时,背景点与背景模型差别较大,导致 T_b 值较小,反之亦然。由于 T_b 值会随着摄像机产生的噪声程度不同而改变,而摄像机的噪声是设置阈值 α 时需要抵制的噪声,所以本文用 T_b 来设置 α 。这样做的好处是,在创建聚类时就不会为噪声点创建新的聚类。

如果将核密度估计看成是以带宽 (bandwidth) W 为 bin 的直方图 H ,那么就可以通过直方图波峰和波谷查找方法来获得 T_a 和 T_b 。定义集合 $T = \{i\}$,其中 i 满足

$$(H_i - H_{i-k}) \times (H_i - H_{i+k}) > 0 \quad (11)$$

首先找到该集合中第 1 个满足下式的值即为 T_a 值

$$T_a = \operatorname{argmax} \left(\frac{H_{i-1} - H_i}{H_i - H_{i+1}} \right) \quad 0 < i < T_{\max} \quad (12)$$

其中 T_{\max} 为前景阈值的最大可能值,本文设为 0.1。在获得 T_a 后,再设置前景阈值 $\beta = T_a$ 。

然后在 T 中找到满足下式的 i 的值,即

$$T_b = \operatorname{argmax}(H_i) \quad T_a < i \quad (13)$$

由于 T_b 为概率值,因此需转换成阈值 α 。将 T_b 代入到式(9)中,即可用下式来近似获得 α 值。

$$\alpha \cong \delta \sqrt{-2 \log(T_b \cdot \delta \cdot \sqrt{2\pi})} \quad (14)$$

注意:在计算 α 值时,本文假设聚类数和权重值都为 1,表示一个点处像素值变化很小。这是因为当一个点的像素值变化较小时,该点为背景点的可能性较大,所以用背景点来估计 α 值是合理的。

通过上述方法,就可以根据摄像机的噪声情况自适应确定 α 。当包含噪声较多时, α 也相应较大,因此可以有效地抵制噪声对背景模型带来的干扰。

在获得前景阈值 T_a 后,就可以大致分析前景像素点的个数。当前景像素点的个数很多时,则表示背景模型受前景干扰较大。可以根据前景点数来确定 η ,以决定聚类删除的速度。当前景大面积出现时,本文方法可以自动提高阈值 η ,以加速前景聚类的删除速度。根据该思想,将 η 定义为

$$\eta = \varepsilon \cdot \frac{1}{N_{\text{neigh}}} \sum_{i=1}^{N_{\text{neigh}}} C_i^F \quad (15)$$

其中, C_i^F 为第 i 帧属于前景的像素数, N_{neigh} 为相邻帧数,用于计算前景像素数的平均值,本文设置为 3。 ε 为一个转换常数,本文设置为 2, N 为一帧的总像素数。根据式(15),阈值 η 随着前景像素点数的增加而加大,聚类删除的速度也相应加快。

4 实验结果及分析

为了测试本文整体算法的有效性和鲁棒性,对大量标准视频和实际视频进行了测试。受文献[7]以查表的形式来计算 KDE 的启发,本文用一种查表的形式来计算式(9),以优化算法的运算速度。

测试视频包括各种复杂场景下的不同视频,本文方法的测试结果还与经典的多模方法——高斯混合模型方法^[4]和自适应高斯混合模型^[6]进行了对比,所有的方法用相同的基于连通成分^[7]的后处理过程来去除面积过小的孤立区域。图3为实验结果对比图。

图3中第1行为对 Vssn06 的测试结果。该视频为户外场景,场景中树叶随风摆动,光照也在缓慢变化。由于 GMM 算法采用固定的高斯成分数 3,因此在树叶晃动区域,3 个高斯成分并不能足够表示背景状态的变化。而对道路等变化较小的区域,如果依然使用 3 个高斯成分,则会引入不必要的计算量。当采用固定的高斯成分数时,由于高斯成分设置过多,会导致漏检。而高斯成分过少时,又会造成误报。由此可以看出,本文方法的分割效果明显优于 GMM 法。在该场景中用本文方法进行检测,约 51% 的面积的背景可以用少于 3 个聚类表示,而对树叶等复杂背景区域的聚类数则多达 20 个。因此根据背景的变化自适应确定状态数,能够更有效的利用计算资源。与 AGMM 方法相比,本文方法的检测结果中树叶区域引入的虚假前景更少。这是因为本文方法引入了自适应的阈值检测方法,所以能够有效地根据场景变化检测出较优的阈值。

第2行为“tower1_set2”的测试结果。该场景为一个真实的户外监控场景,持续时间很长。从前景分割结果来看,本文算法提取的前景外形不仅更加清晰,而且背景噪声也相应较少。虽然图像上方的道路有大量车辆经过,但由于采用了淘汰过期状态的方法,因此背景模型并未因前景的干扰而被污

染。这说明自适应确定状态数能够较好地反映出背景的状态变化,而聚类的权重值调整则可以突出重要的状态和淘汰过期的状态。

第 3 行为对“highway1”进行测试的结果,该视频拍摄于一段车流量很大的高速公路。由于该视频每帧中都包含有运动的车辆,因此将车辆完整检测出来难度较大。由于该视频中每帧的前景出现的面积都较大,因此利用式(15)将阈值 η 也相应地设置较大。由前景产生的聚类很快就被删除,通过图 3 可以看出,本文方法检测出的前景与 GMM 法和 AGMM 法相比,不仅更加完整,且引入的虚假目标也更少。

从图 3 的 3 个实验可以看出,本文算法的分割结果不仅虚假前景信息较少,而且前景分割较为完整,效果优于 AGMM 和 GMM 方法。

为了定量分析实验结果,对 Vssn06 中多个已标注的标准测试视频进行了测试验证,并与 GMM 法和 AGMM 法进行了比较实验。实验结果采用文献 [10] 中定义的查全率 (recall), 查准率 (precision) 进行度量。其中查全率是检测的正确数与手工标注 (ground truth) 的总数的比值,查准率是检测正确数和总的检测数的比值。图 4 为 GMM 法、AGMM 法以及本文方法对 Vssn06 video7 进行检测的定量实验结果。

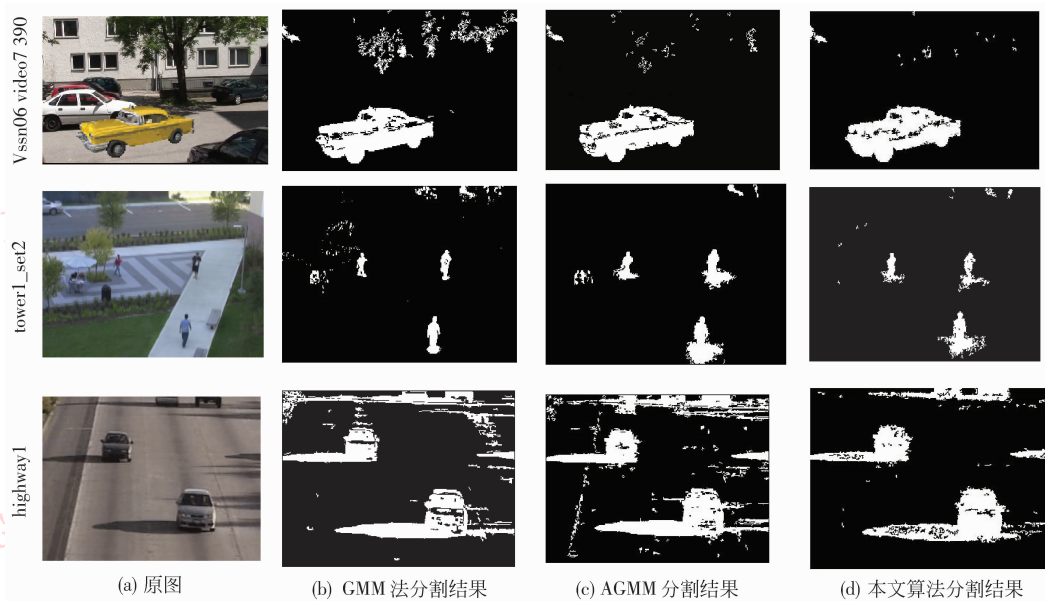


图 3 不同方法分割结果对比图

Fig. 3 The comparison results of different methods

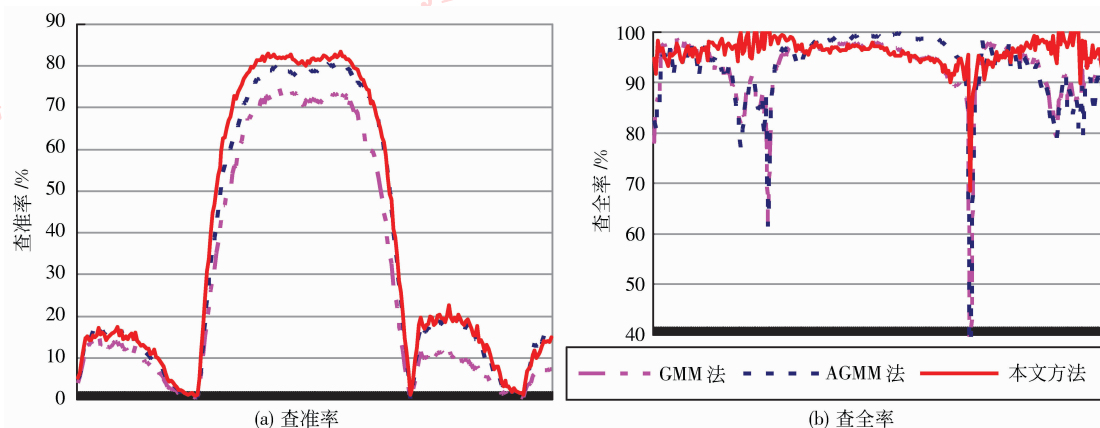


图 4 Vssn06 video7 检测结果以及比较图

Fig. 4 Precision/Recall rates of different methods for Vssn06 video7.

从图 4 和表 1 可以看出,对于 Vssn06 video7 而言,本文算法的查准率和查全率均优于 AGMM 法和 GMM 法,其中查准率的平均值超过 AGMM 法约 2%,超过 GMM 法约 7%。本文算法的查全率优于 AGMM 法约 4%,优于 GMM 法约 5%。整个视频平均值较低的原因是当前景占屏幕的面积过小时,少量的虚假前景信息也会使得与真实前景比值较大。

表 1 给出了对 Vssn06 的平均测试结果。

表 1 Vssn06 video4 和 video7 的平均测试结果

Table 1 Average scores for Vssn06 video4 and video7

视频	不同方法测试结果/%					
	GMM 法		AGMM 法		本文方法	
	查全率	查准率	查全率	查准率	查全率	查准率
Vssn06 video4	87	12	93	18	89	27
Vssn06 video7	88	30	92	34	93	37

从算法的执行速度来看,本文算法可达 15 帧/s 的检测速度,与 AGMM 法接近。其原因是这两种方法的计算复杂度很大程度都来源于背景的高斯成分数以及聚类数。由于本文方法对背景的不同区域区别对待,对于大部分区域,利用式(9)计算前景概率时,聚类数很少,因此仅需要少数几次查表就可以获得前景概率。而将过期的背景状态的删除也有效地减少了不必要的计算量。

5 结 论

本文提出了一种复杂背景下的自适应前景分割算法。该算法的背景模型是由一组带有权重值的聚类所表示。通过本文提出的自适应阈值分割方法,可以自动估算出系统所需的阈值,而通过阈值与权重值的关联,则能够实现根据场景的变化来自适应更新背景模型。实验结果表明,本文方法是有效的和鲁棒的。

参考文献 (References)

- [1] Sheikh Yaser, Shah Mubarak. Bayesian modeling of dynamic scenes for object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(11): 1778-1792.
- [2] Heikkila M, Pietikainen M. A texture-based method for modeling the background and detecting moving objects [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(4): 657-662.
- [3] Zhong Jing, Sclaroff Stan. Segmenting foreground objects from a dynamic textured background via a robust Kalman filter [C]// Proceedings of the Ninth IEEE International Conference on Computer Vision. Washington, DC, USA: IEEE Computer Society, 2003: 44-50.
- [4] Stauffer C, Grimson E L. Learning patterns of activity using real-time tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(3): 747-757.
- [5] Lee D S. Effective Gaussian mixture learning for video background subtraction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(5): 827-832.
- [6] Zivkovic Z, van der Heijden F. Efficient adaptive density estimation per image pixel for the task of background subtraction [J]. Pattern Recognition Letters, 2006, 27(7): 773-780.
- [7] Ahmed Elgammal, Ramani Duraiswami, David Harwood, et al. Background and foreground modeling using nonparametric kernel density estimation for visual surveillance [J]. Proceedings of IEEE, 2002, 90(7): 1151-1163.
- [8] Sheather S J, Jones M C. A reliable data-based bandwidth selection method for kernel density estimation [J]. Journal of the Royal Statistical Society Series B, 1991, 53(3): 683-690.
- [9] Tsai Duming. A fast thresholding selection procedure for multimodal and unimodal histograms [J]. Pattern Recognition Letter, 1995, 16(6): 653-666.
- [10] Maddalena L, Petrosino A. A self-Organizing approach to background subtraction for visual surveillance applications [J]. IEEE Transactions on Image Processing, 2008, 17(7): 1168-1177.