

一种适应户外光照变化的背景建模及目标检测方法

赵旭东¹ 刘鹏¹ 唐降龙¹ 刘家锋¹

摘要 针对户外视频监控存在光照变化这一问题, 提出一个用于准确完成目标检测的实时背景建模框架. 考虑到目标检测的准确性要求, 建立基于帧间像素亮度差统计直方图的像素亮度扰动阈值. 在此基础上, 针对背景建模的实时性要求, 提出一种基于自回归背景模型的参数快速更新方法. 鉴于不同光照变化的适应性要求, 定义对光照变化不敏感的背景纹理模型. 上述模型统称为自回归-纹理 (Auto regression and texture, ART) 模型, 该模型适应于户外光照变化. 基于该模型构建像素亮度和纹理置信区间用于目标检测. 实验结果表明, 该框架能适应和实时跟踪户外背景的光照变化, 并对目标进行准确检测.

关键词 实时自回归更新, 纹理模型, 背景建模, 目标检测, 图像序列处理, 户外视频监控

DOI 10.3724/SP.J.1004.2011.00915

Background Modeling Adaptive to Outdoor Illumination Variation and Foreground Detection Approach

ZHAO Xu-Dong¹ LIU Peng¹ TANG Xiang-Long¹ LIU Jia-Feng¹

Abstract Considering the appearance of illumination variation in outdoor video surveillance, a real-time background modeling framework, which is also composed of accurate foreground detection, is established. In view of the accuracy of foreground detection, a threshold based on the histogram of pixel's intensity difference between neighboring frames is proposed. On account of the real-time background modeling, a fast estimation approach on parameters of autoregressive model is presented. Considering the adaptability to variable illumination, a texture background model insensitive to outdoor illumination variation is designed. Thus, a uniform model named auto regression and texture (ART) is obtained. According to the established confidence intervals with perturbation of pixel's intensity and its local texture, foreground in scenes with different illumination variations is successfully detected. The experimental results indicate that the framework is adaptive to and can exactly track outdoor illumination variation in real time. Moreover, foreground detection is successfully accomplished.

Key words Real-time autoregressive estimation, texture model, background modeling, foreground detection, image sequence processing, outdoor video surveillance

背景建模为户外视频监控的目标检测提供必要的支持. 常见的背景模型包括统计模型和结构模型^[1]. 统计背景模型源于图像序列像素亮度在时间上的统计特性. Stauffer 和 Grimson 的混合高斯模型^[2] 通过统计像素亮度的变化情况描述多个背景模式, 并采用 EM 算法更新该模型的参数. 基于核密度估计的模型^[3-8] 采用非参数像素亮度的概率估计方法估计表示每个背景的分量. 运动预测模型采用主成分分析^[9-10] 或隐马尔科夫模型^[11-12] 来估计像

素亮度的变化. Hwang 等提出了一个噪声的通用指数模型^[13] 用于变化检测. Chang 等给出了带有状态标签的滑动窗口, 并依据处于滑动窗口内部像素点的状态标签分布建立了基于信息熵图像的背景模型^[14]. 文献 [15] 提取 HSV 空间的色相特征构建了像素级统计度量函数. 结构背景模型源于空间相关性. 文献 [16] 给出了一个用于描述背景时空域和频域特征的贝叶斯框架. Kim 等将背景像素亮度量化到压缩编码的码书中, 建立了码书模型^[17]. 文献 [18] 提出一个基于神经网络的无监督贝叶斯分类器, 用于构建背景结构模型. 文献 [19] 提取 HSV 空间的色相定义相似性度量函数, 并联合区域纹理特征构建结构背景模型. 上述背景模型采用像素的颜色、亮度等时间特性及其空间相关性等特征, 在某些方面呈现出良好的性能, 如能够适应光照的渐变和动态背景, 但对光照的快速变化比较敏感, 对带有户外快速光照变化的目标检测失效.

户外光照变化主要包括: 随时间推移产生的缓慢光照变化^[20] 和由阴晴变化 (如云层快速遮挡等) 引起的快速光照变化. 准确的目标检测结果要求背

收稿日期 2010-12-01 录用日期 2011-03-22
Manuscript received December 1, 2010; accepted March 22, 2011

国家自然科学基金 (60702032), 黑龙江省自然科学基金 (F201021), 中国航天工业创新基金 (CAST200814), 哈工大自然科学基金创新基金 (HIT.NSRIF.2008.63) 资助

Supported by National Natural Science Foundation of China (60702032), Natural Science Foundation of Heilongjiang Province (F201021), China Academy of Space Technology Innovation Foundation (CAST200814), and Natural Scientific Research Innovation Foundation in Harbin Institute of Technology (HIT.NSRIF.2008.63)

1. 哈尔滨工业大学计算机科学与技术学院 哈尔滨 150001
1. School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001

景模型对户外光照变化有良好的适应能力. 与此同时, 户外视频监控要求对背景模型进行实时的估计. 事实上, 目标检测的准确性与背景建模的实时性之间存在一定矛盾. 统计背景模型更关注目标检测结果的准确性, 而结构背景模型则更强调背景估计的实时性. 为解决背景模型对户外光照变化的适应性问题, 有研究开始引入纹理特征用于背景建模, 并将其用于对目标的准确检测. Tian 等将纹理特征融入基于亮度统计特征的混合高斯模型 (Mixture of Gaussian, MoG)^[21], 用以实现对目标的准确检测. Heikkilä 等借鉴 MoG 的建模方法, 构建了用于目标检测的纹理 (Local binary pattern, LBP) 结构背景模型^[22]. 另一方面, 针对背景建模的实时性要求, Manzanera 等采用基于递归非线性滤波的帧差模型 ($\Sigma - \Delta$)^[23] 用于户外视频监控的目标检测.

本文提出一个用于目标检测的背景建模框架, 该框架适用于户外视频监控中产生的缓慢和快速光照变化. 首先, 考虑到目标检测的准确性要求, 建立基于帧间像素亮度差统计直方图的像素亮度扰动阈值, 并将其引入到基于自回归 (Auto regression, AR) 的快速背景估计中. 针对户外视频监控产生的图像子序列设计递推最小二乘法, 对 AR 模型的参数进行实时估计. 鉴于背景模型对不同户外光照变化的适应性要求, 定义对光照变化不敏感的纹理 (Texture) 模型, 最终将上述模型统一于自回归-纹理 (Auto regression and texture, ART) 模型. 基于 ART 模型构建的像素亮度和纹理置信区间, 作为区分背景光照变化和前景目标的判据. 该框架无需区分光照变化类型, 可用于在带有光照变化的户外视频监控中进行目标检测, 并满足背景建模的实时性和目标检测的准确性要求.

1 理论背景及研究概要

首先, 以带有户外光照变化的图像序列为研究对象, 对 AR 模型作简单介绍. 在此基础上, 给出同时满足背景建模的实时性、对户外光照变化的适应性、以及目标检测的准确性要求的 ART 框架.

1.1 AR 模型

带有户外光照变化的图像序列 $\{I_t(p, q)\}$ 的亮度观测值随时间的变化而发生变化, 构成一个时间序列. 其中, $I_t(p, q)$ 表示帧 t 在位置 (p, q) 处像素亮度的观测值, 简记为 I_t . AR 模型是用于对平稳时间序列进行建模和预报的时域分析方法, 用于拟合平稳时间序列. 若 $\{I_t\}$ 具有平稳性, 则可用 AR 模型为背景建模. 把具有如下结构的模型称为 n 阶自回归 (AR (n)) 模型^[24]:

$$\begin{cases} I_k = \varphi_1 I_{k-1} + \varphi_2 I_{k-2} + \dots + \varphi_n I_{k-n} + \varepsilon_k \\ \varphi_n \neq 0 \end{cases} \quad (1)$$

其中, φ_i 为 I_{k-i} 对 I_k 的阶系数, 随机干扰序列 $\{\varepsilon_k\}$ 为白噪声序列 ($\varepsilon_k \sim N(0, \sigma_k^2)$).

1.2 ART 框架

ART 框架如图 1 所示. 户外视频监控易受成像系统噪声的干扰而影响目标检测的结果. 考虑到目标检测的准确性要求, 对图像序列 $\{I_t\}$ 进行亮度扰动阈值 Th 的动态更新, 并将其用于图像序列 $\{I_t\}$ 的平稳性预处理中, 对亮度值进行修正, 得到平稳的图像序列 $\{M_t\}$. 在此基础上, 针对背景建模的实时性要求, 设计用于快速估计 AR 模型阶系数 φ_i 的方法, 对 φ_i 进行实时更新. 当上述背景估计的阶系数稳定时, 得到对当前修正帧 M_k 的预报帧 \hat{M}_k . 由预报帧 \hat{M}_k 和亮度扰动阈值 Th 共同构建的亮度置信区间 $R(\hat{M}_k)$, 用于判定当前观测帧 I_k 是否存在缓慢光照变化. 鉴于背景模型对不同户外光照变化的适应性要求, 分别计算纹理观测帧 T_k 和预处理纹理预报帧 \hat{T}_k , 设计相应的背景纹理模型 \cap_{T_k, \hat{T}_k} , 并构建相应的纹理置信区间 $R(\hat{T}_k)$, 最终将其用于判定当前观测帧 I_k 是否存在快速光照变化. 上述亮度置信区间 $R(\hat{M}_k)$ 和纹理置信区间 $R(\hat{T}_k)$ 用于区分户外光照变化和由前景目标引起的亮度和纹理变化.

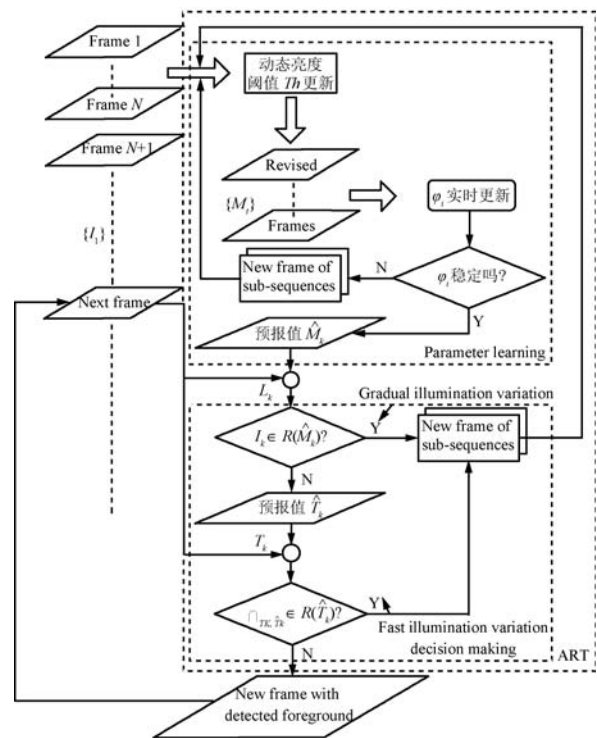


图 1 ART 模型的组成结构框图
Fig. 1 Framework of ART model

ART 框架由参数学习 (Parameter learning) 和决策判定 (Decision making) 两部分组成. 下文将围绕上述两部分展开. 其中, 参数学习部分包括图像序列的平稳性预处理和基于 AR 模型的快速背景估计; 决策判定部分包括实时的背景纹理模型以及基于亮度和纹理置信区间的目标检测.

2 ART 参数学习

ART 框架参数学习的目的在于构建基于像素亮度的实时背景估计, 用于准确的目标检测. 户外视频监控存在光照变化, 由其引发的背景弱光或背景强光会导致成像系统噪声的产生, 进而引发像素亮度扰动, 破坏图像序列的平稳性. 此外, 户外视频监控要求对背景进行实时的估计. 为解决上述问题, 考虑将实时的平稳性预处理引入到背景估计中, 共同构成 ART 参数学习部分.

2.1 平稳性预处理

为克服像素亮度扰动的影响, 考虑对图像序列 $\{I_t\}$ 进行实时的平稳性预处理. 为此, 首先构建像素级的帧间亮度差统计直方图如下:

$$C_m(p, q) = \text{Histogram} |I_{t+1}(p, q) - I_t(p, q)| \quad (2)$$

其中, $C_m(p, q)$ 记录位置 (p, q) 处帧间亮度差值为 m 出现的次数, $m = 0, 1, 2, \dots, 255$. 户外光照变化在视觉效果上表现为背景亮度的连续变化, 帧间的亮度差相对稳定, 因此假定式 (2) 所示的像素级帧间亮度差统计直方图均服从均值为 0 的高斯 (Gaussian) 正向分布 (即该直方图满足高斯分布大于 0 的部分). 该分布表示如下:

$$P(|C_m - 0| < c\sigma) = 2\Phi(c) - 1 \quad (3)$$

其中, σ 为总体的标准差, Φ 为标准正态分布的分布函数. 当式 (3) 值为 0.95 时, $c = 1.96$, 即假定像素帧间亮度扰动的置信度为 0.95, 则可定义像素亮度扰动参数如下:

$$Th(p, q) = 1.96 \hat{\sigma}(p, q) \quad (4)$$

其中, $\hat{\sigma}(p, q)$ 为位置 (p, q) 处样本的标准差. 由式 (2) 和式 (4) 及样本标准差的定义得基于帧间像素亮度差统计直方图的像素亮度扰动阈值如下:

$$Th(p, q) = 1.96 \times \frac{\sum m^2 C_m(p, q)}{\sum C_m(p, q) - 1} \quad (5)$$

在此基础上, 对图像序列进行平稳性预处理, 即作如下图像替换:

$$M_{t+1} = \begin{cases} M_t + 1, & \text{若 } I_{t+1} - I_t > Th \\ M_t - 1, & \text{若 } I_{t+1} - I_t < -Th \\ M_t, & \text{否则} \end{cases} \quad (6)$$

其中, $\{M_t\}$ 表示预处理后的平稳图像序列. M_t 表示已处理的当前帧 I_t 的估计值, 其初始值为 $M_0 = I_0$. M_{t+1} 为待处理帧 I_{t+1} 的估计值. Th 即为图像序列 $\{I_t\}$ 的亮度扰动阈值, 其定义如式 (5) 所示. 式 (6) 中, 除 Th 外其余均可在线表述. 针对目标检测的实时性要求, 可将户外图像序列拆成长度相等的子序列 $\{I_{(i,j)} | i = 0, 1, 2, \dots, j = 0, 1, \dots, N-1\}$, 其中, $I_{(i,j)} = I_{i \times N + j}$. N 为子序列长度, 亦即式 (2) 所示的帧间像素亮度差统计直方图计算窗口的大小. 用前一个子序列 $\{I_{(i-1,j)}\}$ 来估计当前子序列 $\{I_{(i,j)}\}$ 的亮度扰动阈值 Th , 即可实时的对 $\{I_{(i,j)}\}$ 进行图像替换.

2.2 基于 AR 的快速背景估计

经预处理的图像序列 $\{M_t\}$ 具有平稳性, 可用 AR 模型为背景建模. 将式 (6) 代入式 (1) 可建立基于 n 阶自回归 (AR(n)) 的背景模型如下:

$$\begin{cases} M_k = \varphi_1 M_{k-1} + \varphi_2 M_{k-2} + \dots + \varphi_n M_{k-n} + \varepsilon_k \\ \widehat{M}_k = \varphi_1 M_{k-1} + \varphi_2 M_{k-2} + \dots + \varphi_n M_{k-n} \end{cases} \quad (7)$$

其中, M_k 和 \widehat{M}_k 分别代表预处理后的图像序列 $\{M_t\}$ 的第 k 帧观测值和第 k 帧预报值. 式 (7) 亦可用矩阵的形式表述. 采用最小二乘法可得阶系数向量的如下估计:

$$\varphi_N = (X_N^T X_N)^{-1} X_N^T Y_N \quad (8)$$

其中, X_N , Y_N 和 φ_N 分别表示为

$$Y_N = \begin{pmatrix} M_{n+1} \\ M_{n+2} \\ \vdots \\ M_N \end{pmatrix}, \quad \varphi_N = \begin{pmatrix} \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_n \end{pmatrix}, \quad X_N = \begin{pmatrix} \mathbf{m}_{(1)} \\ \mathbf{m}_{(2)} \\ \vdots \\ \mathbf{m}_{(k)} \end{pmatrix} \quad (9)$$

行向量 $\mathbf{m}_{(i)} = (M_{n+i-1}, M_{n+i-2}, \dots, M_i)$. 令矩阵 $P_N = (X_N^T X_N)^{-1}$, 则由式 (9) 可得阶系数 φ_i 的递推关系式:

$$\varphi_{N+1} = P_{N+1} X_{N+1}^T Y_{N+1} \quad (10)$$

其中, $P_{N+1} = (X_{N+1}^T X_{N+1})^{-1}$. X_{N+1} 和 Y_{N+1} 分别表示如下:

$$X_{N+1} = \begin{pmatrix} X_N \\ \mathbf{m}_{(k+1)} \end{pmatrix}, \quad Y_{N+1} = \begin{pmatrix} Y_N \\ M_{N+1} \end{pmatrix} \quad (11)$$

由分块矩阵乘法和矩阵求逆公式可得:

$$P_{N+1} = \left(I - P_N \frac{\mathbf{m}_{(k+1)}^T \mathbf{m}_{(k+1)}}{1 + \mathbf{m}_{(k+1)} P_N \mathbf{m}_{(k+1)}^T} \right) P_N \quad (12)$$

其中, I 为单位阵. 将式 (11) 和式 (12) 分别代入式 (10) 得:

$$\varphi_{N+1} = \varphi_N + K_{N+1} (M_{N+1} - \mathbf{m}_{(k+1)} \varphi_N) \quad (13)$$

其中, 权系数

$$K_{N+1} = \frac{1}{1 + \mathbf{m}_{(k+1)} P_N \mathbf{m}_{(k+1)}^T} P_N \mathbf{m}_{(k+1)}^T$$

更新后的 φ_{N+1} 仍为 n 维列向量.

上述基于 AR (n) 的背景模型中, 递推阶系数 φ_{N+1} 所需的 P_{N+1} 和 K_{N+1} 均可通过递推得到, 且只需进行矩阵乘法运算. 因此, 针对背景模型实时更新的需要, 阶系数 φ_i 在线学习的 AR (n) 模型适合作为户外视频监控的背景模型. 当 $\sum_{i=1}^n \varphi_i \rightarrow 1$ (即: $|\sum_{i=1}^n \varphi_i - 1| \leq T_s$, T_s 由用户指定) 时, 认为 φ_N 已学习稳定, 则由式 (7) 生成预报帧 \widehat{M}_k . 同时, ART 框架开始进入决策判定部分.

3 ART 决策判定

ART 框架决策判定的目的在于构建基于纹理的实时背景估计, 用于适应不同的户外光照变化, 并准确地完成目标检测. 决策判定部分包括: 建立实时的背景纹理模型和构建用于目标检测的亮度、纹理置信区间两部分.

3.1 实时的背景纹理模型

背景的纹理特征对户外光照变化不敏感^[21-22], 因此, 设计实时的背景纹理模型, 用于适应带有缓慢光照变化或是快速光照变化的目标检测. 针对背景纹理建模的实时性要求, 采用 LBP_{8,1} 算子分别对全图像 I_k 和 \widehat{M}_k 中的每个像素点 (p, q) 进行特征提取, 并对以 (p, q) 为中心的区域 ($D = R_{\text{region}} \times R_{\text{region}}$, R_{region} 由用户指定) 进行求和统计, 可得与全图像 I_k 和 \widehat{M}_k 分别对应的纹理观测帧 T_k 和预处理纹理预报帧 \widehat{T}_k . 在此基础上, 定义了区域纹理判别函数:

$$\cap_{h, h_b}(p, q) = \frac{\sum_D 2 \|h(p, q)\| \cdot \|h_b(p, q)\| \cdot \cos \theta}{\sum_D \|h(p, q)\|^2 + \|h_b(p, q)\|^2} \quad (14)$$

其中, h 和 h_b 分别代表 I_k 和 \widehat{M}_k 中位置 (p, q) 处的特征值. 式 (14) 的分子表示对区域 D 中 h 和 h_b 的内积求和 (θ 为 h 和 h_b 的夹角). 背景的区域纹理特征不受光照变化的影响, 其数学表述为 $h \approx h_b$, 亦即

$\|h - h_b\|^2 \approx 0$. 为更准确地描述背景区域纹理的光照不变性, 将上述完全平方的数学表述修改为如式 (14) 所示, 作为位置 (p, q) 处的区域纹理判别函数. 考虑到背景建模的实时性要求, 将 h 和 h_b 分别定义为位置 (p, q) 处的 LBP_{8,1} 标量.

3.2 基于亮度和纹理置信区间的目标检测

首先, 对 ART 模型设计基于亮度置信区间的目标检测方法. 由式 (7) 得: $M_k - \widehat{M}_k = \varepsilon_k$. 随机干扰序列 $\{\varepsilon_k\}$ 为白噪声序列 ($\varepsilon_k \sim N(0, \sigma_k^2)$). 当置信度为 0.95 时, 得到亮度置信区间如下:

$$R(\widehat{M}_k) = (\widehat{M}_k - 1.96\sigma_k - Th, \widehat{M}_k + 1.96\sigma_k + Th) \quad (15)$$

其中, σ_k 代表 $\{\varepsilon_k\}$ 样本的标准差. ART 基于亮度的目标检测方法如图 1 所示: 当 $I_k \in R(\widehat{M}_k)$ 时, 检测到带有缓慢光照变化的背景; 否则, 需进行基于纹理的目标检测判断.

其次, 对 ART 模型设计基于纹理置信区间的目标检测方法, 用于区分背景的快速光照变化和前景目标. 由式 (14) 可知, 当 $\cap_{T_k, \widehat{T}_k}(p, q) \rightarrow 1$ 时, 纹理观测帧 T_k 和预处理纹理预报帧 \widehat{T}_k 存在近似的纹理结构特征. ART 模型基于纹理的置信区间如下:

$$R(\widehat{T}_k) = (1 - T_b, 1) \quad (16)$$

其中, T_b 为用于进行 ART 纹理判断的阈值, 由用户指定. ART 基于纹理的目标检测方法如图 1 所示: 当 $\cap_{T_k, \widehat{T}_k} \notin R(\widehat{T}_k)$ 时, 检测为前景目标; 否则为带有快速光照变化的背景.

4 实验结果及分析

如图 2 所示, 选取摄像机固定拍摄的两组分别代表缓慢光照变化和快速光照变化的户外视频作为实验样本, 其对应的图像子序列的长度分别为 124 帧和 123 帧. 考虑到目标检测的准确性要求以及背景建模的实时性要求, 采用带有纹理检测的 MoG 模型^[21], 基于纹理直方图统计的 LBP 模型^[22], 基于帧差的 $\Sigma - \Delta$ 模型^[23], 以及本文的 ART 模型对图 2 所示的实验样本分别进行背景建模和目标检测实验. 所选模型的参数均选取与该实验样本对应的最优值. 鉴于 LBP 对灰度的纹理不变性, 采用 MoG, $\Sigma - \Delta$ 以及本文的 ART 模型对 R, G, B 分量分别建模, 采用 LBP 模型对亮度分量单独建模.

ART 模型的参数包括: 图像子序列长度 N , AR 模型的阶数 n 及其平稳性判定阈值 T_s , 以及纹理模型的区域参数 R_{region} 及其前景判定阈值 T_b . 上述参数均由用户设定. 考虑到目标检测的准确性要求, n 和 N 应选取较大值, T_b 和 T_s 应选取较小值; 针对背景建模的实时性要求, n , N 以及 R_{region} 则应选取较

小值, 并为 T_b 和 T_s 留出足够的余量. 事实上, 快速光照变化仅产生于短时图像序列. 因此, 鉴于对不同光照变化的适应性要求, 应选取较小的图像子序列长度 N . 其次, 考虑到前景纹理的细粒度要求以及快速光照变化的区域性要求, 应选取较小的纹理学习区域 R_{region} . 另外, n , T_b 和 T_s 的选取应兼顾准确的目标检测和实时的背景建模. 针对图 2 所示的实验样本, 我们选取 $T_s = 0.03$, $R_{\text{region}} = 9$, $T_b = 0.3$, 阶数 $n = 4$, 并令 N 分别为 124 和 123. 背景建模和目标检测的实验结果如图 3~6 所示.

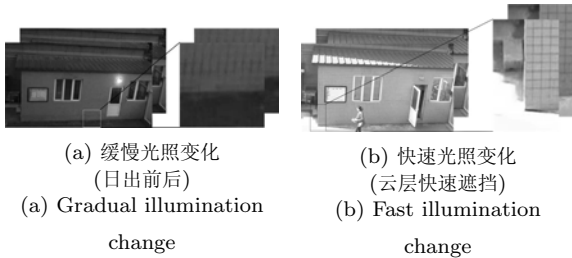


图 2 带有不同户外光照变化的视频

Fig. 2 Videos in different outdoor illumination variations

图 3 为缓慢光照变化条件下基于不同背景模型的目标检测结果. 在弱光照条件下, 图 3(a) 对应于图 2(a) 所示图像子序列中第 124 帧的选中区域, 图 3(b)~3(e) 分别为以 MoG^[21], LBP^[22], $\Sigma - \Delta$ ^[23] 以及 ART 作为背景模型的目标检测结果. 图 3(b) 有少量斑点噪声, 图 3(c) 存在误判、漏判, 图 3(d) 存在大量噪声, 图 3(e) 的检测结果较为理想.



图 3 带有缓慢光照变化的目标检测结果
Fig. 3 Foreground detection in gradual illumination variation

图 4 为 ART 模型在 RGB 空间针对图 2(a) 所示的选取区域中心进行目标检测的亮度跟踪结果. 如图 4 所示, R, G, B 任意通道中的三条点线代表式 (6) 和 (15) 所示的预处理后的平稳图像序列 $\{M_t\}$ 在该点构成的时间序列和亮度置信区间, R, G, B 任意通道中的折线代表实际观测的图像序列 $\{I_t\}$ 在该点构成的时间序列. 由图 4 可知, 缓慢光照变化的亮度随机扰动分布在式 (15) 构成的亮度置信区间内, 由该亮度置信区间可以检测到代表前景目标的亮度值.

图 5 显示了快速光照变化条件下基于不同背景模型的目标检测结果. 其中, 图 5(a) 和图 5(f) 分别对应于图 2(b) 所示图像子序列中第 56 帧和第 80 帧的选中区域. 图 5(a) 的背景较亮而图 5(f) 的背景较暗, 显示了由阴晴变化引起的快速光照变化. 图 5(b)~5(e) 分别为以 MoG^[21], LBP^[22], $\Sigma - \Delta$ ^[23] 以及 ART 作为背景模型的目标检测结果. 在强光照条件下, 图 5(b) 和图 5(d) 存在斑点噪声, 图 5(c) 存在误判, 图 5(e) 的检测结果较为理想, 表明 ART

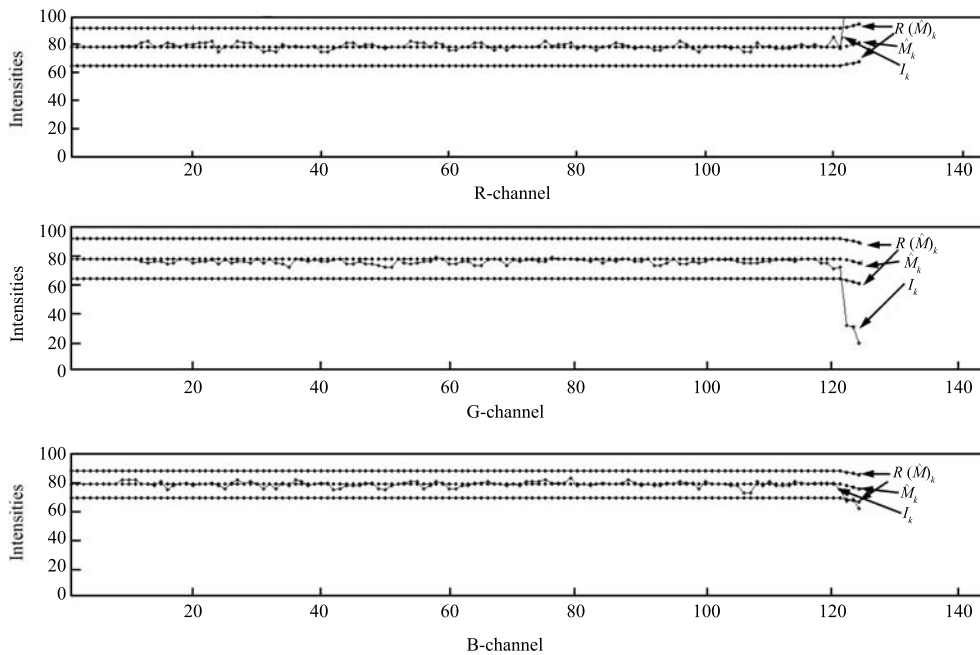


图 4 带有缓慢光照变化的检测结果描述

Fig. 4 Description of detection results in gradual illumination variation

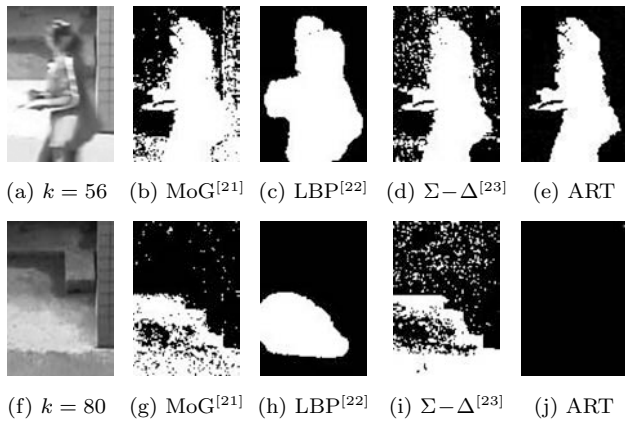


图 5 带有快速光照变化的目标检测结果

Fig. 5 Foreground detection in fast illumination variation

背景模型可以用于强光照条件下的目标检测. 在快速光照变化条件下, 图 5(g)~5(i) 均存在对快速光照变化的误判, 图 5(j) 则显示了 ART 模型在目标检测方面对快速光照变化的适应性.

图 6 为 ART 模型在 RGB 空间针对图 2(b) 所示的选取区域中心进行目标检测的亮度跟踪结果. 如图 6 所示, R, G, B 任意通道中的三条点线代表式 (6) 和 (15) 所示的预处理后的平稳图像序列 $\{M_t\}$ 在该点构成的时间序列和亮度置信区间, R, G, B 任意通道中的折线代表实际观测的图像序列 $\{I_t\}$ 在该点构成的时间序列. 由图 6 可知, 快速光照变化的亮度变化大部分分布在式 (15) 构成的亮度置信区间内, 由该亮度置信区间可以检测到代表前景目标的

亮度值. 进一步观察发现, ART 背景模型对快速光照变化具有一定的跟踪能力.

表 1 和表 2 分别为 MoG^[21], LBP^[22], $\Sigma - \Delta$ ^[23] 以及 ART 模型 ($n = 4$) 用于目标检测的程序执行时间和误判 (False positive, FP)、漏判 (False negative, FN) 结果. 所用的硬件配置为: CPU-Intel 双核 2.2 G, 内存 2 G; 所用的软件编译环境为: Matlab V7.1.

表 1 带有户外光照变化的目标检测程序执行时间比较

Table 1 Comparison of executing time of programs for foreground detection in outdoor illumination variations

| 背景模型 | 程序平均执行时间 (s/frame) | |
|-----------------------------------|--------------------|--------|
| | 缓慢光照变化 | 快速光照变化 |
| MoG ^[21] | 0.6927 | 0.9545 |
| LBP ^[22] | 3.6102 | 4.6426 |
| $\Sigma - \Delta$ ^[23] | 0.0182 | 0.0310 |
| ART ($n = 4$) | 0.0992 | 0.1250 |

表 2 表明: MoG^[21], LBP^[22] 和 $\Sigma - \Delta$ ^[23] 的方法在缓慢光照变化的场景中 FP、FN 的值较大, 但仍然有效, 其中, $\Sigma - \Delta$ ^[23] 存在较大的误判; 快速光照变化条件下, 上述方法均失效. ART 模型则满足户外缓慢和快速光照变化条件下目标检测的准确性要求.

对于缓慢光照变化而言, 由图 3、表 1 和表 2 可知: MoG^[21] 的检测结果虽然较为准确, 但背景实时




图 6 带有快速光照变化的检测结果描述

Fig. 6 Description of detection results in fast illumination variation

表 2 带有户外光照变化的目标检测精度比较

Table 2 Comparison of accuracies of programs for foreground detection in outdoor illumination variations

| 背景 模型 | 缓慢光照变化 | | 快速光照变化 | |
|-----------------------------------|---------|-------|---------|--------|
| | FP | FN | FP | FN |
| MoG ^[21] | 1 348 | 1 780 | 134 879 | 7 276 |
| LBP ^[22] | 949 | 4 612 | 32 970 | 16 634 |
| $\Sigma - \Delta$ ^[23] | 157 586 | 1 544 | 180 300 | 4 914 |
| ART ($n = 4$) | 368 | 824 | 3 821 | 2 109 |

更新困难, 不宜用于目标的在线检测; LBP^[22] 的检测结果存在漏判和误判, 且背景实时更新困难 (区域亮度直方图向量的相似性度量计算量大), 漏判产生的原因在于弱光条件下前景目标的灰度纹理与背景灰度纹理近似, 前景边缘存在少量误判则由 LBP 的亮度直方图特征向量是基于区域的这一原因造成 (在同一区域内, 处在前景边缘外部的像素与前景边缘处的像素具有相似的亮度直方图); $\Sigma - \Delta$ ^[23] 的方法较之目标检测的准确性更强调背景建模的实时性; ART 方法的参数均可实时更新, 在对目标进行在线检测的同时, 抑制了缓慢光照变化中的像素亮度随机扰动, 因此检测的效果最为理想。

对于快速光照变化而言, 由图 5、表 1 和表 2 可知: MoG^[21] 由于选取纹理特征的简单性, 仍将部分像素的快速光照变化误判为前景目标, 且背景实时更新困难, 不宜用于目标的在线检测; LBP^[22] 的检测结果对快速光照变化存在误判 (事实上, 在文献 [22] 中的实验结果也指出这一问题, 如开关灯), 且背景实时更新困难; $\Sigma - \Delta$ ^[23] 的方法对快速光照变化敏感, 较之目标检测的准确性更强调背景建模的实时性; ART 方法在对目标进行在线检测的同时, 适用于强光照条件下的目标检测, 较之其他方法更能区分背景的快速光照变化和前景目标, 因此检测的效果最为理想。

5 结论

本文提出了一种适应户外不同光照变化的背景建模及目标检测方法, 即构建了一个基于像素亮度时间特性和区域纹理特性的 ART 框架. 考虑到户外视频监控对背景建模的实时性以及目标检测的准确性要求, 建立了基于帧间像素亮度差统计直方图的像素亮度扰动阈值, 并将其引入到背景实时估计中, 构建了像素亮度置信区间; 进而定义了对光照变化不敏感的区域纹理模型, 构建了纹理置信区间. 实验结果表明, ART 模型可用于户外各种光照条件下的移动目标检测, 在满足目标检测实时性要求的同时,

能够准确地区分背景的光照变化和前景目标, 对光照变化具有一定的跟踪能力.

References

- 1 Takagi M, Shimoda H [Author], Sun Wei-Dong [Translator]. *Handbook of Image Analysis*. Beijing: Science Press, 2007 (Takagi M, Shimoda H [著], 孙卫东 [译]. 图像处理技术手册. 北京: 科学出版社, 2007)
- 2 Stauffer C, Grimson W E L. Adaptive background mixture models for real-time tracking. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Fort Collins, USA: IEEE, 1999. 246–252
- 3 Elgammal A M, Harwood D, Davis L S. Non-parametric model for background subtraction. In: Proceedings of the 6th European Conference on Computer Vision. London, UK: Springer-Verlag, 2000. 751–767
- 4 Elgammal A, Duraiswami R, Harwood D, Davis L S. Background and foreground modeling using nonparametric kernel density estimation for visual surveillance. *Proceedings of IEEE*, 2002, **90**(7): 1151–1163
- 5 Parag T, Elgammal A, Mittal A. A framework for feature selection for background subtraction. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE, 2006. 1916–1923
- 6 Perez A, Larranaga P, Inza I. Bayesian classifiers based on kernel density estimation: flexible classifiers. *International Journal of Approximate Reasoning*, 2009, **50**(2): 341–362
- 7 Banerjee A, Burlina P. Efficient particle filtering via sparse kernel density estimation. *IEEE Transactions on Image Processing*, 2010, **19**(9): 2480–2490
- 8 Kristan M, Skocaj D, Leonardis A. Online kernel density estimation for interactive learning. *Image and Vision Computing*, 2010, **28**(7): 1106–1116
- 9 Monnet A, Mittal A, Paragios N, Visvanathan R. Background modeling and subtraction of dynamic scenes. In: Proceedings of the 9th IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE, 2003. 1305–1312
- 10 Bravo I, Mazo M, Lazaro J L, Gardel A, Jimenez P, Pizarro D. An intelligent architecture based on field programmable gate arrays designed to detect moving objects by using principal component analysis. *Sensors*, 2010, **10**(10): 9232–9251
- 11 Guo L H, Li J H, Chen L Y, Yang S T. Gibbs distributions and Markov random field model: application on background modeling in video surveillance. In: Proceedings of the SPIE Real Time Imaging VIII. San Jose, USA: SPIE, 2004. 264–270
- 12 Xu Jian, Ding Xiao-Qing, Wang Sheng-Jin. Object occupancy probabilistic field based multi-view moving object detection and correspondence. *Acta Automatica Sinica*, 2008, **34**(5): 609–612 (徐剑, 丁晓青, 王生进. 基于目标存在概率场的多视角运动目标检测与对应算法. 自动化学报, 2008, **34**(5): 609–612)

- 13 Hwang Y, Kim J S, Kweon I S. Change detection using a statistical model in an optimally selected color space. *Computer Vision and Image Understanding*, 2008, **122**(3): 231–242
- 14 Chang M C, Cheng Y J. Motion detection by using entropy image and adaptive state-labeling technique. In: Proceedings of the IEEE International Symposium on Circuits and Systems. New Orleans, USA: IEEE, 2007. 3667–3670
- 15 Liu Peng, Xu Jing, Liu Jia-Feng, Tang Xiang-Long. An algorithm for real-time analysis of rain-affected videos. *Acta Automatica Sinica*, 2010, **36**(10): 1371–1378
(刘鹏, 徐晶, 刘家锋, 唐降龙. 一种受雨滴污染视频的快速分析方法. 自动化学报, 2010, **36**(10): 1371–1378)
- 16 Li L Y, Huang W M, Gu I Y H, Tian Q. Statistical modeling of complex backgrounds for foreground object detection. *IEEE Transactions on Image Processing*, 2004, **13**(11): 1459–1472
- 17 Kim K, Chalidabhongse T H, Harwood D, Davis L. Background modeling and subtraction by codebook construction. In: Proceedings of the IEEE International Conference on Image Processing. Washington D. C., USA: IEEE, 2004. 3061–3064
- 18 Culibrk D, Marques O, Socke D, Kalva H, Furht B. Neural network approach to background modeling for video object segmentation. *IEEE Transactions on Neural Networks*, 2007, **18**(11): 1614–1627
- 19 Xu Jian, Ding Xiao-Qing, Wang Sheng-Jin, Wu You-Shou. Background subtraction based on a combination of local texture and color. *Acta Automatica Sinica*, 2009, **35**(9): 1145–1150
(徐剑, 丁晓青, 王生进, 吴佑寿. 一种融合局部纹理和颜色信息的背景去除方法. 自动化学报, 2009, **35**(9): 1145–1150)
- 20 Toyama K, Krumm J, Brumitt B, Meyers B. Wallflower: principles and practice of background maintenance. In: Proceedings of the 7th IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE, 1999. 256–261
- 21 Tian Y L, Lu M, Hampapur A. Robust and efficient foreground analysis for real-time video surveillance. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE, 2005. 1182–1187
- 22 Heikkilä M, Pietikainen M. A texture-based method for modeling the background and detecting moving objects. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(4): 657–662
- 23 Manzanera A, Richefeu J C. A new motion detection algorithm based on $\Sigma - \Delta$ background estimation. *Pattern Recognition Letters*, 2007, **28**(3): 320–328
- 24 Fan Jian-Qing, Yao Qi-Wei [Author], Chen Min [Translator]. *Non-linear Time Series: Nonparametric and Parametric Methods*. Beijing: Higher Education Press, 2005
(范剑青, 姚琦伟 [著], 陈敏 [译]. 非线性时间序列: 建模、预报及应用. 北京: 高等教育出版社, 2005)



赵旭东 哈尔滨工业大学计算机科学与技术学院博士研究生. 2007 年获哈尔滨工业大学硕士学位. 主要研究方向为数字信号处理、时间序列分析、图像处理和模式识别. 本文通信作者.

E-mail: zhaoxudong@hit.edu.cn

(**ZHAO Xu-Dong** Ph.D. candidate at the School of Computer Science and

Technology, Harbin Institute of Technology. He received his master degree from Harbin Institute of Technology in 2007. His research interest covers digital signal processing, time series analysis, image processing, and pattern recognition. Corresponding author of this paper.)



刘鹏 哈尔滨工业大学计算机科学与技术学院副教授. 2007 年获哈尔滨工业大学博士学位. 主要研究方向为数字信号处理、模式识别、图像处理与机器视觉. E-mail: pengliu@hit.edu.cn

(**LIU Peng** Associate professor at the School of Computer Science and Technology, Harbin Institute of Tech-

nology. He received his Ph.D. degree from Harbin Institute of Technology in 2007. His research interest covers digital signal processing, pattern recognition, image processing, and computer vision.)



唐降龙 哈尔滨工业大学计算机科学与技术学院教授. 1995 年获哈尔滨工业大学博士学位. 主要研究方向为光学字符识别、生物特征识别、图像处理及模式识别. E-mail: tangxl@hit.edu.cn

(**TANG Xiang-Long** Professor at the School of Computer Science and Technology, Harbin Institute of Tech-

nology. He received his Ph. D. degree from Harbin Institute of Technology in 1995. His research interest covers OCR, biometrics, image processing, and pattern recognition.)



刘家锋 哈尔滨工业大学计算机科学与技术学院副教授. 1996 年获哈尔滨工业大学博士学位. 主要研究方向为模式识别, 机器学习, 图像处理, 图像理解与机器视觉. E-mail: jefferyliu@hit.edu.cn

(**LIU Jia-Feng** Associate professor at the School of Computer Science and Technology, Harbin Institute of Tech-

nology. He received his Ph. D. degree from Harbin Institute of Technology in 1996. His research interest covers pattern recognition, machine learning, image processing, image understanding, and computer vision.)