

基于自适应粒子滤波器的物体跟踪

夏利民 张良春

(中南大学信息科学与工程学院,长沙 410075)

摘要 利用分类概念及粒子滤波理论,提出了一种基于自适应粒子滤波器的物体跟踪算法。将 Boosting 算法引入粒子滤波器,构建了自适应粒子滤波器,该方法首先利用背景信息和目标信息建立特征分类器,将分类器的输出结果作为粒子滤波系统观测的重要信息,进行粒子权值的计算,并在跟踪过程中不断更新特征分类器,从而自适应地更新粒子的权值。实验结果表明,该算法可以根据背景信息的不同自适应地选择特征,对于存在遮挡、形变及背景干扰等情况,依然可以很好地对目标进行稳定跟踪。

关键词 粒子滤波器 自适应特征选择 跟踪 Boosting 算法

中图分类号:TP391.41 文献标识码:A 文章编号:1006-8961(2009)01-0112-06

Object Tracking Based on Adaptive Particle Filter

XIA Li-min, ZHANG Liang-chun

(School of Information Science and Engineering of Central South University, Changsha 410075)

Abstract An object tracking algorithm based on adaptive particle filter is proposed in this paper. Boosting algorithm is introduced into particle filter algorithm, and adaptive particle filter is constructed. Features classifiers are constructed utilizing object information and background information, and the outputs of these classifiers taken as important information of observations of particle filter are used to calculate particles' coefficient. Also, these classifiers are updated during tracking in order to update particles' coefficient adaptively. The experiment result shows that the tracking algorithm we proposed can adaptively select features for tracking utilizing different background information, in applications such as existence of covering, appearance changed, clutter in the background and illumination changing. The objects can be tracked stably.

Keywords particle filter, adaptive features selecting, tracking, Boosting algorithm

1 引言

近年来,粒子滤波器成为研究的热点,它通过非参数化的蒙特卡罗模拟方法实现递推贝叶斯滤波,可以广泛应用于任何非线性模型和非高斯噪声的目标跟踪^[1,2]。

目前,对粒子滤波器跟踪技术的研究主要集中在粒子滤波技术的算法研究上,如粒子滤波器的退化问题等,而对于目标描述,研究的却不多。通常的做法是在跟踪之前,先人为地选取某种特征(如颜

色、纹理、形状或者其他特征等)来表征目标,并在跟踪过程中使用这些特征进行系统观测、计算和更新粒子权值^[3,4]。该类方法主要存在以下问题:(1)表征目标的特征通常是根据人为经验得来的,而且在跟踪过程中通常是不变的,对于不同的环境不具有自适应性;(2)选用的特征通常都是单一的,不能满足复杂环境下稳定跟踪的要求。

分类方法^[5]是近年来出现的一种比较新的方法,其主要思想是将跟踪问题归结于分类问题,通过训练一个可以将目标和背景分开的分类器,并不断更新分类器以达到跟踪的目的,如 Avidan 等

基金项目:国家自然科学基金项目(79816101);湖南省自然科学基金项目(05JJ30121)

收稿日期:2007-01-14;改回日期:2007-07-03

第一作者简介:夏利民(1963~),男,教授,博士生导师。主要研究方向为模式识别与图像处理。E-mail: xlm@mail.esu.edu.cn

采用 Adaboost 方法训练弱分类器,然后通过组合得到强分类器进行运动物体跟踪^[6],Robert T 等人采用 log 相似度自适应地对特征进行选择^[7],Helman 等人提出一个 5 种色彩空间自适应转换算法进行人脸跟踪算法^[8],Avidan 采用支持向量机进行跟踪^[9]等。该类方法根据目标信息和背景信息选择特征,适应性明显提高,而且一般采用多特征,对于复杂环境的跟踪,在跟踪的稳定度及精度上都有较为明显的提高。但是该类方法也具有某些问题,如特征分类器的选择及更新就是个难点。

本文将分类方法与粒子滤波算法结合起来,提出了一种基于自适应特征选择的粒子滤波跟踪算法。该算法先通过 Boosting 方法选择特征,建立特征分类器,并在跟踪过程中不断更新特征分类器,将分类器分类函数的输出结果用于粒子滤波框架中系统观测进行粒子权值的计算和更新。该算法根据背景信息不同,自适应地选择特征,对于存在遮挡、形变及背景干扰等情况,仍然可以很好地对目标进行稳定跟踪。

2 粒子滤波

设动态系统 k 时刻的状态向量为 \mathbf{X}_k ,观测向量为 \mathbf{Y}_k 以及观测序列 $\mathbf{Y}_{1:k} = \{\mathbf{Y}_1, \dots, \mathbf{Y}_k\}$,则系统状态转移模型和观测模型定义为

$$\begin{cases} \mathbf{X}_k = F(\mathbf{X}_{k-1}, \mathbf{U}_k) \\ \mathbf{Y}_k = H(\mathbf{X}_k, \mathbf{V}_k) \end{cases} \quad (1)$$

式中, $F(\cdot)$ 是状态转移模型, \mathbf{U}_k 是系统噪声; $H(\cdot)$ 是观测模型, \mathbf{V}_k 是观测噪声。如果状态转移模型和观测模型转化为状态转移概率 $p(\mathbf{X}_k | \mathbf{X}_{k-1})$ 和观测概率 $\tilde{p}(\mathbf{Y}_k | \mathbf{X}_k)$,那么状态估计问题就转化为计算后验概率 $\hat{p}(\mathbf{X}_k | \mathbf{Y}_{1:k})$ 。如果后验概率和观测概率是非线性的和非高斯的,那么粒子滤波是求解该问题的有效方法。粒子滤波的核心思想是利用一组加权的随机样本 $\{\mathbf{X}_k^{(n)}, w_k^{(n)}\}_{n=1}^N$ 近似表示后验概率 $\hat{p}(\mathbf{X}_k | \mathbf{Y}_{1:k})$,系统动态求解由 Bayesian 迭代推理过程完成^[3],根据粒子滤波原理,样本的权重 $w_k^{(n)}$ 可定义为

$$w_k^{(n)} = \tilde{p}(\mathbf{Y}_k | \mathbf{X}_k^{(n)}), \quad \sum_{n=1}^N w_k^{(n)} = 1 \quad (2)$$

式中, $\tilde{p}(\mathbf{Y}_k | \mathbf{X}_k^{(n)})$ 表示样本 $\mathbf{X}_k^{(n)}$ 的观测概率。则 k 时刻的系统状态估计为

$$\hat{\mathbf{X}}_k = E(\mathbf{X}_k | \mathbf{Y}_{1:k}) = \sum_{n=1}^N w_k^{(n)} \mathbf{X}_k^{(n)} \quad (3)$$

3 特征选择及特征分类器的更新

3.1 特征

本文采用 3 种不同类型特征空间中的特征:颜色特征、Harr 小波特征和 LBP(local binary pattern)纹理特征。采用这 3 种特征主要是因为这 3 类特征可以进行快速计算,适于实时跟踪。

(1) 颜色特征

采用 Robert 等人提出的颜色特征空间中的方法^[7],颜色特征空间由下列公式表示:

$$F_1 = \{w_1 R + w_2 G + w_3 B | w_i \in [-2, -1, 0, +1, +2]\}$$

w_i 对应于 -2 到 2 之间的整数,这样的组合可以达到 5^3 种,但最终选择了其中的 49 种特征作为本文的颜色特征。(具体选择过程详见参考文献^[7])

(2) Harr 小波特征

目前应用的 Harr 小波特征主要有 3 种形式,如图 1 所示。




图 1 Harr 小波特征的 3 种形式

Fig. 1 Three types of Harr wavelet

Viola 在文献^[10]中指出,Harr 小波在目标识别过程中不但具有非常好的性能,而且适于快速计算,实验中,对图像做水平方向和垂直方向的 3 次抽样,并从中选取 60 个 Harr 小波特征。(如何选择 Harr 小波详见参考文献^[10])。

(3) LBP 纹理特征

LBP 作为纹理算子可以很好地用来分析图像纹理特征^[11]。假定给定图像函数 $I(x, y)$,为了刻画图像像素点在某邻域内的灰度变化,考虑像素点的 $m \times m$ 邻域,LBP 纹理算子计算公式如下

$$\text{LBP}(x_c, y_c) = \sum_{p=0}^{2^m-1} s(G_p - G_c) 2^p$$

其中, G_c 、 G_p 分别为中心 (x_c, y_c) 处及邻域内各像素点的灰度值, $s(x)$ 为一个二值函数,定义如下:

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (4)$$

对于一个 3×3 邻域,LBP 纹理算子模板及计算

过程如图 2 所示,具体的 LBP 算法详见参考文献[11]。




图 2 LBP 算子的 3 × 3 邻域及计算过程

Fig.2 LBP's 3 × 3 mode and its calculation

3.2 特征选择

假定开始时已经检测到了目标区域,如图 3 所示,图中矩形框为目标区域,将该区域标为正例样本,将周围背景相同块大小区域标为反例样本。




图 3 标定目标区域

Fig.3 Demarcate object area

为了获得更多的样本,将矩形框分别向左右方向和上下方向移动 1 ~ 2 个像素点得到的样本作为正例样本,相应地取周围背景相同大小的块作为反例样本,这样就得到了 n 个正例样本和 m 个反例样本,然后利用 Adaboost 方法对样本进行训练,选择特征,具体算法如下:

给定 $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$, x_i 表示第 i 个图像块, $y_i = 0, 1$ 表示样本为反例样本和正例样本, (x_i, y_i) 表示第 i 个图像块样本, $1 \leq i \leq l$, l 为得到样本的个数,可取值 40。

初始化 $w_{1,i} = \frac{1}{2n}, \frac{1}{2m}$ 分别对应 $y_i = 0, 1$, 其中 $w_{1,i}$ 表示第 1 次第 i 个样本对应的权值。

(1) 对每一特征 j 用 w_i 训练 h_j , 具有 $\varepsilon_j = \sum_i w_{i,i} [h_j(x_i) - y_i]$, w_i 表示第 t 次样本对应的权值 $t = 1, \dots, T$, $1 \leq j \leq n$, n 为备选特征总数。 $(h_j$ 表示特征 j 的弱分类假设, h_j 可表示为 $h_j(x) = \begin{cases} 1 & p_j f_j(x) < p_j \theta_j \\ 0 & \text{其他} \end{cases}$, 其中 $f_j(x)$ 为特征值,

θ_j 为阈值, p_j 为不等式方向符号因子)

(2) 选择 $h_t(\cdot) = h_k(\cdot)$, 对于 $\forall j \neq k, \varepsilon_k < \varepsilon_j$,

且 $\varepsilon_t = \varepsilon_k$

(3) 更新 $w_{t+1,i} = w_{t,i} \beta_i^{1-\varepsilon_i}$, 其中 $\varepsilon_i = 0, 1$ 表示对样本错分或正确划分, $\beta_i = \frac{\varepsilon_i}{1 - \varepsilon_i}$

最后的分类函数结果为 $h(x) = \sum_{i=1}^T a_i h_i(x) \geq$

$$\frac{1}{2} \sum_{i=1}^T a_i \text{ 其中 } a_i = \log \frac{1}{\beta_i}$$

至此,得到了 T 个特征,相应地也到了 T 个初始化特征分类器。

3.3 特征分类器的更新

3.2 节中采用的是离线 Adaboost 算法,不适用于特征分类器的实时更新,因此,需要一个实时 Boosting 方法。Oza 等人在文献[12]中指出,对于离线 Boost 方法与在线 Boost 方法,在给定相同的训练样本,且迭代次数 $N \rightarrow \infty$, 它们具有收敛一致性。基于此,提出的分类器更新算法如下:

对于新来的训练样本(对应检测到的目标区域和对应的背景区域),初始化重要性权值 $\lambda = 1$

计算 $h_{n,t} = \text{update}(h_{n,t}, (x, y), \lambda)$

$$n = 1, \dots, N; t = 1, \dots, T$$

若样本正确划分: $\lambda_{n,t}^c = \lambda_{n,t}^c + \lambda$

若样本错误划分: $\lambda_{n,t}^w = \lambda_{n,t}^w + \lambda$

$$\text{特征分类器的错误率 } \varepsilon_{n,t} = \frac{\lambda_{n,t}^w}{\lambda_{n,t}^c + \lambda_{n,t}^w}$$

选择 ε_n 对应的分类器作为特征分类器,

$$\varepsilon_n = \arg \min_n (\varepsilon_n, t)$$

$$\text{计算 } a_n = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_n}{\varepsilon_n} \right)$$

$$\lambda = \begin{cases} \lambda \cdot \frac{1}{2(1 - \varepsilon_n)} & \text{样本正确划分} \\ \lambda \cdot \frac{1}{2\varepsilon_n} & \text{样本错误划分} \end{cases}$$

替换 $\varepsilon_n > 0.5$ 的分类器(使用一个新的特征),

赋 $\lambda_{n,t}^c, \lambda_{n,t}^w$ 为 1

4 基于自适应特征选择的粒子滤波跟踪

本文的特征选择和分类器的跟踪是在粒子滤波跟踪框架下完成的,跟踪过程分为两部分:一部分为

特征选择及更新,另一部分为粒子滤波跟踪。假设初始时已经检测到目标区域,首先进行特征分类器的初始化以及粒子状态的初始化,然后通过粒子滤波跟踪算法对目标进行跟踪,其中,在粒子滤波跟踪过程的系统观测阶段,利用特征分类器计算粒子状态的 $h(x)$,并由 $h(x)$ 来确定粒子权值,跟踪完成后,将跟踪到的区域作为新的样本再对分类器进行更新,再继续下一帧跟踪,跟踪具体算法如下:

(1) 初始化

① 初始化特征分类器(用3.2节方法)

得到 T 个特征分类器,初始分类假设为

$$h(x) = \sum_{i=1}^T a_i h_i(x) \geq \frac{1}{2} \sum_{i=1}^T a_i$$

式中 $a_i = \log \frac{1}{\beta_i}$

② 初始化 N 个粒子:

已知目标的初始状态向量

$\mathbf{X}_0 = (x_0, y_0, \hat{x}_0, \hat{y}_0, \omega_0)$, 其中 $x_0, y_0, \hat{x}_0, \hat{y}_0, \omega_0$ 分别是目标的在 x, y 方向的初始坐标、初始速度及初始角速度,由下式得到 N 个粒子参数的初始值 $\{(\mathbf{X}_0^i, \omega_0^i), i = 1, \dots, N\}$, 其中 $\mathbf{X}_0^i, \omega_0^i$ 分别是粒子的初始状态向量及对应的权值。

$\mathbf{X}_0^i = \mathbf{X}_0 + \mathbf{b}\xi^i$, $\mathbf{b} = [b_1, b_2, b_3, b_4, b_5]^T$, $\omega_0^i = 1/N$ 其中, ξ^i 为 $[-1, 1]$ 之间的随机数, $b_1 \sim b_5$ 为常数。

(2) 预测

利用系统状态转移方程对粒子状态进行预测:

$$\mathbf{X}_k^i = \mathbf{A}\mathbf{X}_{k-1}^i + \mathbf{B}\omega_{k-1}$$

式中, $\mathbf{X}_k^i, \mathbf{X}_{k-1}^i$ 分别为第 i 个粒子在第 $k, k-1$ 时刻的状态向量, ω_{k-1} 为 $[-1, 1]$ 之间的随机数, \mathbf{A} 为状态转移矩阵, \mathbf{B} 为粒子传播半径向量。

(3) 系统观测

① 利用特征分类器计算每个粒子状态的 $h(X)$:

$$h(X) = \sum_{i=1}^T a_i h_i(X)$$

② 用下式给每一个样本加权:

$$\tilde{w}_k^{(n)} = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(1-h)^2}{2\sigma^2}}$$

并将其归一化 $w_k^{(n)} = \frac{\tilde{w}_k^{(n)}}{\sum_{i=1}^N \tilde{w}_k^{(i)}}$, 使得 $\sum_{n=1}^N w_k^{(n)} = 1$;

(4) 输出: 计算样本集的均值 $E[\mathbf{X}_k] =$

$\sum_{n=1}^N w_k^{(n)} \mathbf{X}_k^{(n)}$, 将对应的结果标定为目标区域。

(5) 更新特征分类器

① 对于新标定的样本,初始化权重 $\lambda = 1$ (用3.3节中方法)

② 对于 For $n = 1$ to N

For $t = 1$ to T

计算 $h_{n,t}, \varepsilon_n, a_n, \lambda$

替换替换 $\varepsilon_n > 0.5$ 的分类器(使用一个新的特征), 赋 $\lambda_{n,t}^c, \lambda_{n,t}^w$ 为 1

③ 得到更新后的分类函数:

$$h(X) = \sum_{i=1}^T a_i h_i(X) \geq \frac{1}{2} \sum_{i=1}^T a_i$$

(6) 重采样: 重采样概率密度为 $w_k^{(n)}$ 的粒子 $(\mathbf{X}_k^{(n)}, w_k^{(n)})$ 以获得 N 个随机粒子 $(\tilde{\mathbf{X}}_k^{(n)}, 1/N)$; 至此一次跟踪完成, 下一次跟踪从步骤(2)开始。

5 仿真实验与结果分析

在一台 P4-2.4G, 512M 内存的 PC 上对本文的算法进行了仿真实验。首先对第 1 帧目标区域进行标定, 对目标进行仿射变换, 得到初始化运动参数; 实验中, 选取了 49 个颜色特征, 60 个 Harr 小波特征, 并采用 3×3 模板提取 LBP 特征, 将这些特征作为一个统一的备选特征库, 通过初始化方法, 选择了 30 个分类器作为最初的特征分类器, N 同样取为 30, 跟踪过程中通过本文提供的方法, 不断更新和替换特征分类器, 对运动目标进行稳定跟踪。实验视频由摄像头拍摄, 帧率为 25fps, 前两个实验是在室内进行的, 对目标存在遮挡, 背景中出现干扰以及照明变化等情况进行了实验, 结果如下:

图 4 中, 对人脸区域进行跟踪, 并与文献[3]和文献[4]中的所用方法进行了对比, 文献[3]、[4]中对应的方法用 PF (particle filter) 和 KPF (Karman particle filter) 表示, 选用特征是颜色特征, 本文提出的方法用 APF (adaptive particle filter) 表示, 跟踪区域对应为矩形框区域。在跟踪过程中出现了干扰(人脸), 遮挡、光照变化以及形变(目标离镜头的远近以及侧面), 从实验过程中可以看出; 对于一般的粒子滤波算法, 当出现严重遮挡的时候, 出现了误跟踪和失跟踪现象; 而对于 KPF, 在没有干扰的情况下, 跟踪效果比较理想, 但当出现干扰、遮挡以及形变时, 跟踪稳定性和准确度都不是很理想; 而本文提出的算法则可以很好地处理这些问题, 能够稳定跟踪, 效果比较明显。



图 4 对人脸区域进行跟踪
Fig. 4 Tracking of human face area

图 5 中第 1 行,对黑色方形物体进行跟踪结果,跟踪过程中出现了形变,背景干扰、遮挡以及光照变化等情况,从实验结果来看,即使在出现非常大的干扰(背景为黑色区域)的情况下,本文提出的跟踪算法仍然可以对目标进行稳定跟踪。第 2 行为黑色物体跟踪过程对应的特征选择过程。可以看出,在正常情况下(如第 102 帧图以前),颜色特征(对应“+”号线条)作为跟踪的首要特征,所占比例最大,Harr 特征(对应“×”号线条)也较

为明显,而对于该实验中所选目标区域,LBP 特征(对应“O”号线条)不是十分明显,选择比例很小;在出现背景干扰时(黑色背景,如第 165 帧图附近),颜色特征下降很快,而 Harr 特征作为重要特征,所占比例较大,同时 LBP 特征比例也有部分的提高;在遮挡区域(如第 247 帧图附近),颜色特征较 Harr 特征明显,比例上升;在存在光照变化时,颜色特征有所下降,Harr 特征有所上调,而 LBP 特征在整个跟踪过程中变化不大。

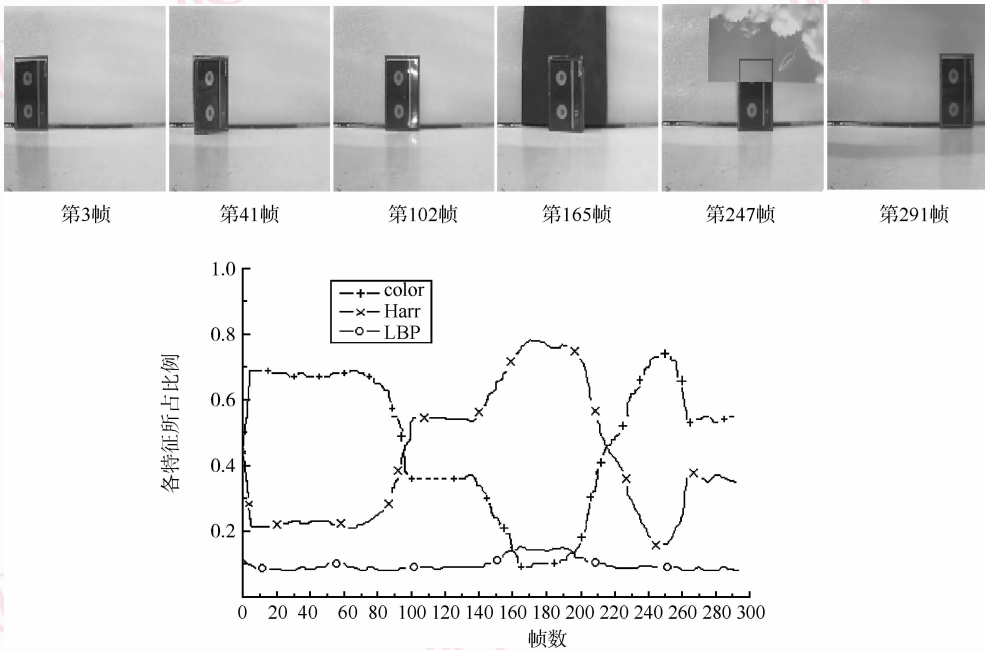


图 5 对方形黑色物体进行跟踪及对应的自适应特征选择示意图
Fig. 5 Tracking of black rectangle object and corresponding adaptive feature selecting

为了不失一般性,还对公路上运行的车辆进行了跟踪实验,结果如图6所示。

从上述3组实验可以看出,本文提出的跟踪算法通过对特征的自适应选择,在存在形变、遮挡、背

景干扰以及光照变化的情况下,依然可以对目标进行稳定而有效的跟踪,而且所有的实验都是在帧率为25fps下完成的,可见算法也可以满足实际应用中实时性要求。



图6 对车辆进行跟踪示意图

Fig. 6 Tracking of vehicle in freeway

6 结论

跟踪过程中目标形变、遮挡、背景干扰以及光照变化等问题的解决一直是跟踪过程中的难点。本文利用分类概念及粒子滤波理论,提出了一种基于自适应粒子滤波跟踪算法,该算法根据背景信息的不同,自适应的选择特征,可以很好地解决上述问题。跟踪的速度主要与特征计算以及跟踪粒子的多少有关,论文采用了一些适于快速计算的特征,并提出了采用实时 Boosting 方法更新特征分类器,并将分类函数的输出结果作为系统观测的重要信息,对粒子权值进行计算和更新,大大缩短了处理时间,适于实时跟踪。与传统的跟踪算法相比,本文提出的跟踪算法在对目标稳定跟踪的同时,还具有较快的跟踪速度,因此,在工程应用中具有更为重要的现实意义。

参考文献 (References)

- 1 Gunnarsson F, Bergman N. Particle filters for positioning, navigation, and tracking [J]. IEEE Transactions on Signal Processing, 2002, **50**(2):425-437.
- 2 Gordon N J, Salmond D J, Smith A F M. Novel approach to nonlinear/ non-Gaussian Bayesian state estimation [J]. IEE Proceedings F. Radar Signal & Process, 1993, **140**(2):107-113.
- 3 Doucet A. On sequential simulation monte carlo sampling methods for bayesian filtering [J]. Statistics and Computing, 2000, **10**(3):197-208.
- 4 Ye Jian-bo, Xia Li-min. Eyes tracking based on kalman particle filter

[J]. Computer Engineering. 2006, **32**(3):196-198. [叶剑波,夏利民. 基于卡尔曼粒子滤波器的人眼跟踪 [J]. 计算机工程, 2006, **32**(3):196-198.]

- 5 Chen Hui-min. Joint target recognition and tracking using class specific features [A]. In: Proceedings of Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers [C], Pacific Grove, CA, USA, 2004: 2101-2105.
- 6 Avidan Shai. Ensemble tracking [A]. In: Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition [C], San Diego, CA, USA, 2005:494-501.
- 7 Collins T R, Liu Y. On-line selection of discriminative tracking features [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, **27**(10):1631-1643.
- 8 Stern H, Efron H. Adaptive Color Space Switching for Face Tracking in Multi-Colored Lighting Environments [A]. In: Proceedings of 7th IEEE International Conference on Automatic Face Gesture Recognition [C], Washington DC, USA, 2002:249-254.
- 9 Avidan, Shai. Support vector tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, **26**(8):1064-1072.
- 10 Paul Viola, Michael Jones. Rapid object detection using a boosted cascade of simple features [A]. In: Proceedings of IEEE Computer Vision and Pattern Recognition Kauai Marriott, Hawaii, USA, 2001:142-149.
- 11 Mäenpää T, Pietikäinen M. Texture analysis with local binary patterns [A]. In: Chen C H, Wang P S P eds. Handbook of Pattern Recognition and Computer Vision [M], Hackensack, NJ, USA: World Scientific, 2005:197-216.
- 12 Oza N, Russell S. Online bagging and boosting [A]. In: Proceedings of Eighth International Workshop on Artificial Intelligence and Statistics [C], Morgan Kaufmann, Key West, Florida. USA, 2001:105-112.