

基于全局概率密度搜索的快速目标跟踪

周斌 王军政 沈伟

(北京理工大学自动化学院复杂系统智能控制与决策实验室 北京 100081)

摘要:为了解决均值迁移目标跟踪算法中跟踪窗口对局部概率密度模式敏感的问题,该文提出一种基于全局概率密度搜索的目标跟踪策略。根据目标尺度设定一组从大到小排列的带宽序列,并依次根据每个带宽进行均值迁移迭代收敛,利用大带宽的平滑作用避开局部概率模式的干扰;依靠小带宽进行精确定位,最终收敛到真实目标区域。为了提高均值迁移的收敛速度,引入了 Over-Relaxed 优化策略加速迭代过程。在边界优化算法的收敛条件约束下,根据采用 Over-Relaxed 策略前后相关系数的变化,自适应地调整学习率。实验结果表明全局概率密度搜索能够有效地跟踪快速运动的目标,并且当目标短暂丢失时也有一定的恢复能力; Over-Relaxed 策略也能显著地提高收敛步长,减少迭代次数。

关键词: 目标跟踪; 均值迁移; 全局概率密度搜索; Over-Relaxed 优化

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2010)11-2680-06

DOI: 10.3724/SP.J.1146.2009.01543

Fast Object Tracking with Global Kernel Density Seeking

Zhou Bin Wang Jun-zheng Shen Wei

(Key Laboratory of Complex System Intelligent Control and Decision, School of Automatic Control, Beijing Institute of Technology, Beijing 100081, China)

Abstract: An object tracking algorithm with global kernel density seeking is proposed to avoid local probability mode in mean shift tracking process. Firstly, a monotonically decreasing sequence of bandwidths is obtained according to the object scale. At the first bandwidth, a maximum probability can be found with mean shift, and the next iteration loop started at the previous convergence location. Finally, the best density mode is obtained at the optimal bandwidth. In the convergence process, with the smoothness effect of the large bandwidth, the compact of the local probability mode is avoided, and the precise position of the object can be found with the optimal bandwidth, which is similar to the object scale. To speed up the convergence, Over-Relaxed strategy is introduced to enlarge the step size. Under the convergence rule, the correlation coefficient is used to adopt the learning rate. The experimental results prove that the proposed tracker with global kernel density seeking is robust in high-speed object tracking, and performs well in occlusions. The adaptive Over-Relaxed strategy is effective to lower the convergence iterations by enlarging the step size.

Key words: Object tracking; Mean Shift (MS); Global kernel density seeking; Over-Relaxed (OR)

1 引言

基于核函数的概率密度估计技术在计算机视觉中的应用近年来已经引起了大量学者的关注,其中应用最广泛的就是均值迁移算法(Mean Shift, MS)。均值迁移算法的本质是一种统计迭代算法,能够在特征空间中沿概率密度上升的方向搜索的局部极值,不需要先验知识,适合对未知的数据集进行分析,因此广泛被应用于目标跟踪、视频分割、模式

分类等领域^[1-3]。均值迁移算法利用核函数来计算一个窗口内加权后样本均值迁移向量,通过反复迭代最终收敛到某一个局部密度峰值。

均值迁移作为一种统计迭代算法,收敛性是最受关注的特征之一,特别是实时性要求高的目标跟踪领域。均值迁移算法的收敛性是由核函数决定的,常用的核函数包括均匀核, Epanechnikov 核和高斯核^[4],但是其收敛速度各有不同。均匀核与 Epanechnikov 核收敛速度快,但计算精度不高;高斯核函数计算精度高,应用范围最广,但其收敛路径平滑,收敛速度也较慢。为了得到更快的收敛速度,一些研究者对均值迁移算法进行了深入的研究。

2009-12-01 收到, 2010-05-25 改回

“985”工程学科建设项目(107008200400020)资助课题

通信作者: 周斌 giggsnet@163.com

文献[5]将数据集模糊机制带入均值迁移算法中, 通过不断的更新数据集减少迭代过程中样本点的个数。文献[6]证明了均值迁移算法和 Newton-Raphson 优化算法之间的关系, 并且证明了均值迁移算法实际上是一种边界优化算法。文献[7]提出了 Over-Relaxed 策略来提高边界优化算法的速度。

自从 Comaniciu 将均值迁移算法引入目标跟踪中, 越来越多的研究成果也涌现出来。文献[8]讨论了核函数尺度的选择方法。文献[9]则重新构造了联合空间特征分布的目标跟踪框架, 其优点在于融合了空间结构信息。尽管已经有很多的优化算法被应用, 但是均值迁移算法仍有两个重要的缺陷: 首先, 均值迁移算法是一种局部寻优过程, 很容易陷入局部“错误”的极大模式或极小模式中。其次是采用高斯核函数收敛速度太慢。

本文提出的基于全局概率密度搜索的快速目标跟踪中的“全局概率”和“快速”是两个相对的概念。其中全局概率是采用大尺度窗口与小尺度窗口相结合的方式, 首先利用大尺度窗口快速收敛到目标真实区域附近再利用小尺度窗口进行精确定位。显然和传统的目标跟踪算法相比所需要的迭代次数会有所增加, 因此在每次迭代过程中采用自适应的 Over-Relaxed 策略加速收敛过程, 实现高斯核“快速”跟踪的目的。

2 均值迁移算法

给定 d 维空间 R^d 中有 n 个采样点 $S = \{x_i, 1 \leq i \leq n\}$, 概率密度函数为 $f(x)$, 则在 x 处的核密度估计为

$$\hat{f}_K(x) = \frac{1}{n} \sum_{i=1}^n K_H(x - x_i) \quad (1)$$

其中 $K(\cdot)$ 为核函数, 带宽为 $H \in R^{d \times d}$, $K_H(x) = |H|^{-1/2} K(H^{-1/2}x)$ 。核函数的定义决定了 $K(\cdot)$ 是非负非增且分段连续的。为了简化描述, 通常认为核函数的带宽满足 $H = h^2 I$ 。利用轮廓函数的定义, 核密度估计重写为

$$\hat{f}_K(x) = \frac{c_k}{nh^d} \sum_{i=1}^n k\left(\left\|\frac{x - x_i}{h}\right\|^2\right) \quad (2)$$

其中 $k(\cdot)$ 为 $K(\cdot)$ 的轮廓函数, c_k 为归一化常数。由此寻找局部模式的优化问题也就转换成了梯度上升收敛问题。概率密度 $\hat{f}_K(x)$ 的梯度可以定义为

$$\hat{\nabla} f_K(x) = \nabla \hat{f}_K(x) = \frac{2c_k}{h^2 c_g} \hat{f}_G(x) \cdot m_G(x) \quad (3)$$

其中

$$\hat{f}_G(x) = \frac{c_g}{nh^d} g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) \quad (4)$$

$$m_G(x) = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} - x \quad (5)$$

这里 $g(x) = -k'(x)$, $k(\cdot)$ 定义为轮廓函数 $g(x)$ 的影子核, $m_G(x)$ 为均值迁移向量, 显然 $\hat{\nabla} f_K(x)$ 趋近于 0 时, $m_G(x) = 0$ 。均值迁移过程描述为

$$x \leftarrow \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} \quad (6)$$

均值迁移算法的迭代过程为: 首先从 S 中选择一个数据点 x^i 作为迭代起始点, 然后根据式(6)不断对该点进行迭代更新, 直到收敛到局部密度极大值位置。

3 全局概率密度搜索

在本文引言中已经提到“全局概率”是一个相对的概念, 与之相对的是传统均值迁移算法中利用最优带宽实现“局部”寻优的思想。在目标跟踪中, 若目标运动速度太快, 在相邻帧之间运动范围过大, 跟踪窗通常会收敛到错误的局部极值中。为了解决这个问题, 本文提出一种“粗→精”的跟踪策略, 利用大尺度窗口的平滑作用, 避开局部极大模式的干扰收敛到真实模式附近, 再利用小尺度窗口精确定位目标。

令 $h_d (d = D, D-1, \dots, 0)$ 为单调递减的一组带宽, 其中 h_0 为最优带宽, 在跟踪中为目标的真实尺度, 通常 $h_D \gg h_0$ 。与这一组带宽相对应的一组核密度函数为 $\hat{f}_{h_D} K(\cdot), \hat{f}_{h_{D-1}} K(\cdot), \dots, \hat{f}_{h_0} K(\cdot)$ 。显然当带宽足够大时能得到唯一的概率模式, 也就是说即使迭代的起始点到收敛点的距离较远, 仍然能从全局搜索到最终模式。

图 1 是一组 1 维的数据实验, 其中 $D=4$, 核窗宽为 $h = (300, 200, 100, 70)$, 样本分布为

$$0.28N(0.4, 0.3) + 0.48N(-0.4, 0.3) + 0.14N(-2, 0.5) + 0.1N(2, 0.3) \quad (7)$$




图 1 不同带宽对应的概率密度估计

采用了高斯核 $k(x) = \exp(-\|x_i - x/h\|^2)$ ，针对不同的带宽高斯核概率密度估计结果如图1所示。

显然当 $h_3 = 300$ 时概率密度只有唯一的最大模式，无论从哪开始迭代都能移动到唯一的峰值上；而最优带宽为 $h_0 = 70$ ，估计结果最为精确。在2维的样本空间中进行概率密度估计也同样，通过多带宽的均值迁移迭代，最终能够收敛到全局概率密度模式，并且能够避开局部峰值的影响。

在基于均值迁移的目标跟踪算法中，实际上就是在2维的样本分布中找到匹配程度最高的模式。虽然会受到复杂背景甚至相似目标的干扰，但通常情况下，真实目标区域的模板匹配系数最高，也就是在图像区域中占有最大概率模式；而在干扰区域及相似目标区域中则存在局部概率模式。正是因为真实目标区域占据了整个样本空间中的最大概率模式，因此理论上只要带宽 h 足够大，便能从任意点最终收敛到真实目标区域。但是为了取得更高的计算效率，本文选用的最大带宽往往不超过目标尺度的4倍。

全局概率搜索步骤如下：

- (1) 根据目标尺度确定带宽序列 $h_d (d = D, D-1, \dots, 0)$ ，其中 h_0 为目标尺度。
- (2) 以上一帧图像中目标迭代收敛位置作为当前起始位置，并利用最大带宽进行迭代计算，得到收敛概率模式 $\hat{f}_{h_d, K}(\cdot)$ ，坐标为 \hat{x}_{h_d} 。
- (3) 依次对每个带宽 h_d 用均值迁移算法进行迭代收敛运算，起始点选择上一带宽的收敛位置，最终得到的 \hat{x}_{h_0} 全局概率模式收敛点。

虽然全局概率搜索最终能够得到全局最优的模式，但其缺陷非常明显：这是一种在效率与性能之间折中的办法，虽然比单一带宽的均值迁移算法更稳定，但是需要付出更多的迭代次数，带宽 h_d 越大需要参与计算的样本也越多。

4 Over-Relaxed 快速均值迁移

如上文所述，全局概率搜索在跟踪起始点远离收敛中心时能够定位到全局最优模式，这种情况在跟踪快速运动目标的时候很实际，但考虑到计算量的增加，很有必要提高迭代速度。在目标跟踪中如何提高跟踪速度是备受关注的热点，如 Comaniciu 等人^[10]提出利用 Kalman 滤波器预测目标位置来减少迭代距离，并且在文献[10]中分析了不同的核函数对计算精度与收敛速度的影响。

然而在动态目标跟踪过程中，如以目标脱靶量来控制传感器进行目标瞄准的系统中，目标的位置序列为相对量，其中包含了背景运动信息，无法用

一阶或二阶回归方程建立其状态转移模型因此难以进行预测。

Carreira^[11]证明了高斯核均值迁移算法是一种最大期望算法(EM)。而 Over-Relaxed 策略正适合于提高 EM 算法的收敛速度。正是受这些思想的启发，本文将 Over-Relaxed 引入了基于均值迁移的目标跟踪算法中。

要采用 Over-Relaxed 策略加速迭代过程则必须满足：

定理 1 核函数为 $K(\cdot)$ 的均值迁移算法是二次有界边界优化算法。

这条定理在 Fashing 等人^[6]的文中得到了证明。这条定理同时也证明了均值迁移实际上是一个边界最大化过程。Comaniciu 已证明 $m_G(x) \propto \hat{\nabla} f_K(x) / \hat{f}_G(x)$ ，也就是说均值迁移算法是一个自适应步长的梯度上升算法，但从边界优化的观点来看，通过引入学习率可以使收敛速度更快。定理 1 的证明也说明可以通过 Over-Relaxed 边界条件对动态的均值迁移算法进行加速。Over-Relaxed 迭代式为

$$x^{(k+1)} = x^{(k)} + \beta [m(x^{(k)}) - x^{(k)}] = x^{(k)} + \beta M(x^{(k)}) \quad (8)$$

其中参数 β 为学习率，当 $\beta = 1$ 时，Over-Relaxed 均值迁移则演变为标准均值迁移。当 $\beta > 1$ 的时候会加速上升，文献[7]证明了在 $2 > \beta > 0$ 时，收敛可以保证。但若想设定一个固定的更新率，则有可能在接近最优模式时由于收敛条件的原因出现震荡，而且实现起来也比较困难，然后求解最优化的 β 计算量又太大。

均值迁移目标跟踪的过程就是以相关系数 $\rho[p, q]$ 为目标函数的最优化过程，通过目标相关系数的变化可以得到一种有效的 Over-Relaxed 优化方法：根据匹配程度的高低动态调整学习率 β 的大小，当相关系数变小时则减少学习率；反之亦然。具体计算步骤如下：

- (1) 首先设置学习率 $\beta = (1 + \alpha)\beta$ ，递增参数 $1 > \alpha > 0$ 。
- (2) 利用均值迁移算法计算一步迭代后迁移向量 $m_G(x'_{k+1}) = x'_{k+1} - x_k$ ，其中 x' 为迁移后的坐标。再根据式(8)计算 Over-Relaxed 均值迁移向量 $m_G(x''_{k+1}) = x''_{k+1} - x_k$ 。
- (3) 如果 $\rho[p(x''_{k+1}), q] > \rho[p(x'_k), q]$ 则令 $\beta = (1 + \alpha)\beta$ ， $x_{k+1} = x''_{k+1}$ ；否则 $x_{k+1} = x'_k, \beta = 1$ 。
- (4) 令 $x_k = x_{k+1}$ ，重复执行步骤(2)，直到满足收敛条件。

5 跟踪算法流程

- (1) 跟踪初始化：建立目标特征模型 $q_u =$

$C \sum_{i=1}^n k(\|x_i\|^2) \delta[b(x_i - u)]$; 选择带宽序列 h_d 。

(2) 迭代过程:

(a) 选择最大带宽 h_D , 在上一帧收敛位置计算目标备选特征向量:

$$p_u(x_k) = C_h \sum_{i=1}^{nh} k \left(\left\| \frac{x_k - x_i}{h_D} \right\|^2 \right) \delta[b(y_i - u)]$$

(b) 将 q_u 与 $p_u(x_k)$ 的 Bhattacharyya 相关系数泰勒展开后, 并用均值迁移算法计算其一次迭代后的迁移向量 $m_G(x'_{k+1})$, 以及 Over-Relaxed 均值迁移向量 $m_G(x''_{k+1})$ 。

(c) 根据上文所述, 通过判断 $\rho[p(x'_{k+1}), q]$ 与 $\rho[p(x''_{k+1}), q]$ 大小调整学习率 β , 并且得到本次迭代的收敛位置 x_{k+1} 。

(d) 若满足 $\rho[p(x_{k+1}), q] > th_0$ 或 $x_{k+1} - x_k < 1$ 则执行 e, 否则令 $x_k \leftarrow x_{k+1}$, 返回(b)。

(e) 选择其他带宽 h_d , 执行迭代过程, 直到 h_0 收敛, 当前帧迭代结束。

(3) 获取图像, 再次返回步骤(2), 进行迭代收敛运算。

6 实验结果分析

为了验证本文提出的跟踪算法的有效性, 分别做了静态目标定位实验与动态目标跟踪实验。静态目标定位实验在相同条件下比较了基于全局概率搜索的目标跟踪算法与单一带宽均值迁移算法的定位效果, 以及对采用 Over-Relaxed 加速前后迭代次数的比较。目标跟踪实验中, 同样将本文算法与传统均值迁移算法的效果和实时性进行了对比。

在实验中选择的核函数均为高斯核, 即 $G(\|x\|) = \exp(-\|x_i - x/h\|^2)$, 目标特征模板为 $8 \times 8 \times 8$ 的颜色直方图, 最大带宽取目标尺度的 3 倍, 带宽序列 $h_d = \{3h_0, 2h_0, h_0\}$, 其中 h_0 为目标尺度, Over-Relaxed 优化过程中递增参数 $\alpha = 0.25$, 跟踪收敛条件为 $x_{k+1} - x_k < 1$ 或 $\rho[p(x_{k+1}), q] > 0.95$, 实验用计算机为 Core 2 2.4G, 3GRAM。

6.1 目标定位

在很多文章中都提到均值迁移算法适用于目标位置偏移不大的情况下, 本文的目的就是在不提高时耗的前提下提高算法的稳定性。为了验证本文算法的全局概率搜索能力, 每幅测试图片中选择了 5 个远离真实目标的位置作为迭代的起始点, 固定带宽的均值迁移算法实验结果如图 2 所示, 其中圆点为迭代起始点, 实线为收敛路径, 矩形为收敛区域。显然, 虽然有个别测试点能够收敛到目标区域之外, 大部分都收敛到了错误的区域。

采用全局带宽搜索均值迁移算法实验结果如图 3 所示, 每幅测试图像中搜索的起始点和图 2 中一样, 可以看到, 每一个测试点都成功收敛到了真实的目标区域。为了说明全局概率搜索中带宽序列的作用, 以测试图像 4 为例进行说明。图 4 为 3 个带宽下, 特征向量与目标模板的匹配分布图。显然在 $h_2 = 3h_0$ 的平滑作用下将部分局部峰值的影响削弱了, 即使迭代起始位置距离目标真实位置很远, 也能被引导至全局峰值的附近; 再通过 h_1 和 h_0 的作用最终收敛到真实目标位置, 如图 4(c) 所示。

采用多带宽跟踪后, 跟踪器的稳定性得到了提高, 但是也增加了额外的计算量。本文采用了 Over-Relaxed 策略提高迭代速度, 表 1 中的数据为测试图片 1 中每个测试点收敛所需要的迭代次数, 显然采用 Over-Relaxed(OR) 策略后迭代次数有了大幅度减少。

6.2 目标跟踪

现有的跟踪算法在实际跟踪过程中效果并不理想, 原因在于: (1) 受局部模式影响, 只适用于目标运动较慢的跟踪场合; (2) 跟踪目标丢失后难以恢复。这些缺陷都是由均值迁移算法的局部最优思想引起的。本文采用的“粗→精”的定位策略能够有效的克服这些问题。实验对比如图 5 所示, 测试视频为橄榄球比赛视频, 其中矩形为迭代收敛区域。图中比较了视频中第 121、131、159、167、173、189 帧的跟踪结果。图中第 1 列为单一带宽均值迁




图 2 固定带宽收敛结果

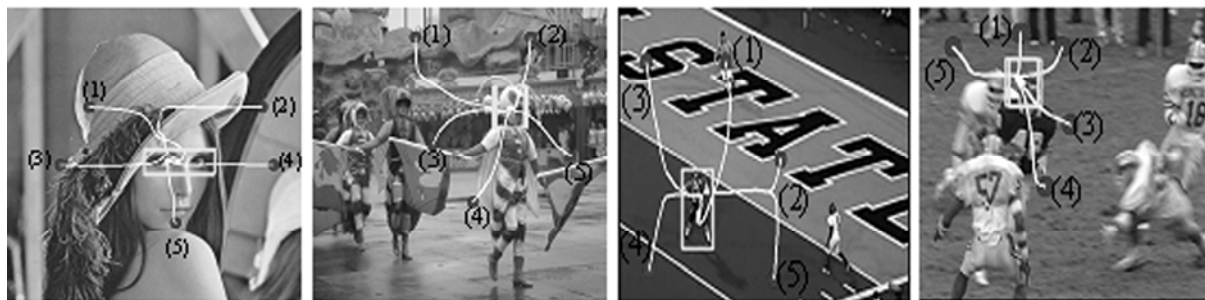


图 3 全局概率搜索结果




图 4 h_2, h_1, h_0 带宽下, 相关系数分布




图 5 跟踪实验对比

表 1 收敛次数对比

	TP1	TP2	TP3	TP4	TP5
MS	61	63	50	56	53
OR-MS	22	17	19	26	22

移跟踪结果, 第 2 列为本文提出的全局概率搜索跟踪结果。现在从第 167 帧开始目标受到局部遮挡, 并且持续了将近 10 帧, 单一带宽均值迁移算法收敛到了错误的区域, 并且没能恢复。采用本文算法后定位的准确性也有所提高, 如第 131, 159 帧; 当目标发生局部遮挡时, 定位也受到一定的影响, 但当遮挡消失后也能够从遮挡中恢复, 如第 173, 189 帧。

与静态定位实验相同, 图 6 为采用 Over-Relaxed 加速策略前后迭代次数的对比。显然在同

一段视频序列中采用 Over-Relaxed 加速策略后收敛迭代次数大大减少了, 特别是在起始点距离目标较远的情况下通过 Over-Relaxed 加速后迭代次数的减少尤为明显。




图 6 迭代次数比较

7 结论

为了解决传统均值迁移算法中跟踪窗口容易受局部概率密度模式干扰的缺陷, 本文提出一种基于全局概率密度搜索的目标跟踪策略。通过在由大到小的带宽中逐步进行迭代运算, 避开局部概率密度极值的干扰收敛到真实目标区域。在跟踪过程中大带宽的平滑与小带宽的精确定位相结合, 提高了跟踪快速目标的稳定性, 并且当遮挡发生而造成目标短暂丢失时也具备一定的自我恢复能力。

同时为了提高跟踪算法的收敛速度, 在前人的研究基础之上, 引入了 Over-Relaxed 策略加速迭代过程, 通过比较加速迭代步长前后对备选区域与真实目标区域匹配系数的影响, 在保证跟踪收敛性的前提下, 动态调整学习率, 实验结果也表明 Over-Relaxed 策略能够有效的增加迭代步长, 进而减少了迭代次数。

参 考 文 献

- [1] 姚红革, 齐华, 郝重阳. 复杂情形下目标跟踪的自适应粒子滤波算法[J]. 电子与信息学报, 2009, 31(2): 275-279.
Yao H G, Qi H, and Hao C Y. Visual target tracking based on the adaptive particle filter in the complex situation [J]. *Journal of Electronics & Information Technology*, 2009, 31(2): 275-279.
 - [2] 张涛, 蔡灿辉. 基于多特征 Mean Shift 的人脸跟踪算法[J]. 电子与信息学报, 2009, 31(8): 1816-1820.
Zhang T and Cai C H. A face tracking algorithm based on multiple feature mean shift [J]. *Journal of Electronics & Information Technology*, 2009, 31(8): 1816-1820.
 - [3] Maggio E and Cavallaro A. Accurate appearance based bayesian tracking for maneuvering targets [J]. *Computer Vision and Image Understanding*, 2009, 113: 544-555.
 - [4] 王永忠, 梁彦, 赵春晖. 基于多特征自适应融合的核跟踪方法[J]. 自动化学报, 2008, 34(1): 393-399.
Wang Y Z, Liang Y, and Zhao C H. Kernel-based tracking based on adaptive fusion of multiple cues [J]. *Acta Automatica Sinica*, 2008, 34(4): 393-399.
 - [5] Zhang K, Kwok J T, and Tang M. Accelerate convergence using dynamic mean shift[C]. Proceedings of the 9th European Conference on Computer Vision. New York, USA, 2006: 257-268.
 - [6] Fashing M and Tomasi C. Mean shift is a bound optimization[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 471-474.
 - [7] Shen C and Brooks M J. A fast global kernel density mode seeking with application to localization and tracking[C]. Proceedings of IEEE International Conference on Computer Vision. Los Alamitos, 2005: 1516-1523.
 - [8] Yin Zhao-zheng and Collins R T. Object tracking and detection after occlusion via numerical hybrid local and global mode-seeking[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition(CVPR), Anchorage, USA, 2008: 1-8.
 - [9] Elgammal A and Duraiswami R. Probabilistic tracking in joint feature-spatial spaces[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington, D.C, USA, 2004: 790-797.
 - [10] Comaniciu D and Meer P. Kernel-based object tracking [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, 25(5): 564-577.
 - [11] Carreira Perpignan M A. Acceleration Strategies for Gaussian Mean shift image segmentation[C]. Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York, 2006: 543-549.
- 周 斌: 男, 1984 年生, 博士生, 研究方向为图像处理、机动目标跟踪与识别。
王军政: 男, 1964 年生, 教授, 博士生导师, 研究领域包括现代检测技术、视觉伺服控制。
沈 伟: 男, 1981 年生, 博士, 讲师, 研究领域为图像处理与嵌入式系统。