

文章编号 1004-924X(2010)10-2297-09

基于组合带宽均值迁移的快速目标跟踪

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:为了解决传统均值迁移(Mean shift)目标跟踪算法中跟踪窗口容易收敛至局部概率模式的问题,提出一种基于组合带宽 Mean Shift 的目标跟踪策略,并建立了一种自适应学习率的 over-relaxed 优化策略以加速收敛过程。根据目标尺度设定了一组从大到小排列的带宽序列,并依次根据每个带宽进行 Mean Shift 迭代收敛运算,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,最终使其收敛到真实目标区域。由于组合带宽 Mean Shift 会造成一定的额外运算量,为此引入 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,组合带宽 Mean Shift 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;实验采用 over-relaxed 策略后,收敛次数减少了 30%~70%。

关键词:目标跟踪;均值迁移;组合带宽;over-relaxed 优化

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20101810.2297

Fast object tracking with multi-bandwidth Mean Shift

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 multi-bandwidth and adaptive over-relaxed accelerated convergence was proposed to avoid the local probability mode in a Mean Shift tracking process. Firstly, a monotonically decreasing sequence of bandwidths was obtained according to the object scale. At the first bandwidth, a maximum probability could be found with the Mean Shift, and the next iteration loop started at the previous convergence location. Finally, the best density mode was obtained at the optimal bandwidth. In the convergence process, the compactness of the local probability mode was avoided with the smoothing effect of the large bandwidth, and the precise position of the object could be found with the optimal bandwidth, which was similar to the object scale. To speed up the convergence, an over-relaxed strategy was introduced to enlarge the step size. Under the convergence rule, the correlation coefficient was used to adjust the learning rate adaptively. The experimental results prove that the proposed tracker with multi-bandwidth Mean Shift is robust in high-speed object tracking, and performs well in occlusions. The experimental results also show that the adaptive over-relaxed strategy reduces the convergence iterations by 30%-70%.

Key words: object tracking; Mean Shift; multi-bandwidth; over-relaxed optimization

收稿日期:2010-01-29;修订日期:2010-03-25.

基金项目:“985”工程学科建设项目(No. 107008200400020)

1 引言

近年来,基于核函数的概率密度估计技术在计算机视觉中的应用已经引起了许多学者的关注,其中应用最广泛的就是均值迁移(Mean Shift)算法。Mean Shift 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,因此被广泛应用于目标跟踪、视频分割、模式分类等领域^[1-3]。Mean Shift 算法利用核函数来计算一个窗口内加权后样本的 Mean Shift 向量,通过反复迭代最终收敛到某一个局部密度峰值。

Mean Shift 作为一种统计迭代算法,收敛性是最受关注的特征之一,特别是在实时性要求高的目标跟踪领域。Mean Shift 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 Mean Shift 算法进行了深入的研究。Zhang 等^[5]将数据集模糊机制带入 Mean Shift 算法中,通过不断地更新数据集减少迭代过程中样本点的个数。Fashing^[6]等证明了 Mean Shift 算法和 Newton-Raphson 优化算法之间的关系,并且证明了 Mean Shift 算法实际上是一种边界优化算法。Salakhutdinov^[7]提出了 over-relaxed 策略来提高边界优化算法的速度。

Comaniciu 将 Mean Shift 算法引入目标跟踪后,涌现出了许多研究成果。Collins^[8]讨论了核函数尺度的选择方法。Elgammal^[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 Mean shift 算法不断得到优化,但其仍有两个重要的缺陷:首先,Mean Shift 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使收敛速度过慢。

本文提出了一种基于组合带宽的 Mean Shift 迭代过程,其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

敛到真实的目标区域。针对组合带宽需要更多计算区域会增加造成计算量增加的问题,在前人研究工作基础上,将边界优化算法中的 over-relaxed 优化策略引入到目标跟踪中,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 over-relaxed 加速方程中的学习率,实现了 Gaussian Mean Shift 过程的自适应加速。

2 Mean Shift 算法

给定 d 维空间 \mathbf{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 $H \in \mathbf{R}^{d \times d}$, $K_H(x) = |H|^{-\frac{1}{2}} K(H^{-\frac{1}{2}x})$ 。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:

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

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 Mean Shift 向量, 显然 $\nabla f_K(x)$ 趋近于 0 时, $m_G(x) = 0$ 。Mean Shift 过程描述为:

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

Mean Shift 算法的迭代过程为:首先从 S 中选择一个数据点作为迭代起始点,然后根据公式(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 组合带宽目标跟踪

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 是一组一维的数据实验,其中 $D=4$,核窗宽为 $h=(300, 200, 100, 70)$,样本分布为:
 $0.28N(0.4, 0.3) + 0.48N(-0.4, 0.3) + 0.14N(-2, 0.5) + 0.1N(2, 0.3)$ 。(7)

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。




图 1 一维数据不同带宽对应的概率密度估计

Fig.1 Density estimation on 1D data set with different bandwidths

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。

在二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,最终能够收敛到真实目标区域,并且能够避开局部峰值的影响。

基于 Mean Shift 的目标跟踪算法实际上就是在二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。

组合带宽 Mean Shift 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 Mean Shift 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} 为最优概率模式收敛点。

虽然组合带宽 Mean Shift 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 Mean Shift 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 Mean Shift

如上文所述,组合带宽 Mean Shift 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 Comanicu 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 Mean Shift 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 Mean Shift 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 Mean Shift 算法是二次有界边界优化算法。

这条定理在 Fashing^[6] 的文中得到了证明。这条定理同时也证明了 Mean Shift 实际上是一个边界最大化过程。Comaniciu 已证明 $m_G(x) \propto \nabla f_k(x)/\hat{f}_G(x)$,也就是说 Mean Shift 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 Mean Shift 算法进行加速。Over-relaxed 迭代公式为:

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

其中:参数 β 为学习率,当 $\beta=1$ 时,over-relaxed Mean Shift 则演变为标准 Mean Shift。当 $\beta>1$ 的时候会加速上升,Xu^[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。

根据 over-relaxed 收敛条件,Shen 等^[7] 建立了一个简单的自适应 over-relaxed 边界优化过程:在学习率中引入递增参数 α ,根据加速前后目标函数的观测值动态调整学习率 β ,具体步骤如下:

(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 $x_{k+1} = x_{k+1}', \beta=1$ 。

令 $x_k = x_{k+1}$,重复执行步骤 2,直到满足收敛条件。

其中 $\rho(\cdot)$ 为目标函数,在图像跟踪中取为 Bhattacharyya 距离。这种方法直观且行之有效,但在实验过程中,仍然会出现震荡问题。为此,本文根据迭代过程中 Bhattacharyya 的变化提出一种自适应学习率的 over-relaxed Mean Shift 过程。

同样,令 $\rho[p(x_k),q]$ 为 x_k 处的 Bhattacharyya 相关系数, q 为目标特征模板,令 $\gamma_{k+1} = \rho[p(x_{k+1}),q]/\rho[p(x_k),q]$, γ_{k+1} 代表了相关系数的变化程度,下标数字为迭代序号。在迭代过程中 $\gamma_1, \gamma_2, \dots, \gamma_3$ 为单调递减过程,最终收敛到 1。本文提出的自适应 over-relaxed Mean Shift 加速策略流程为:

(1) 设定学习率 $\beta=1$,计算初始点 x_k 处的相关系数 $\rho[p(x_k),q]$ 。

(2) 计算 x_k 处均值迁移向量 $m_G(x_{k+1}')$, $m_G(x_{k+1}') = x_{k+1}' - x_k$ 。若 $\rho[p(x_{k+1}'),q] > th_0$,或者 $m_G(x_{k+1}') < \epsilon$,迭代收敛。

(3) 若收敛条件未满足,则令 $x_{k+1} = x_k + \beta m_G(x_{k+1}')$ 。

(4) 计算 x_{k+1} 处 Bhattacharyya 相关系数 $\rho[p(x_{k+1}),q]$ 和 γ_{k+1} 。

(a) 若 $\gamma_{k+1} < 1$,令 $\beta=1, x_{k+1} = x_{k+1}'$;

(b) 若 $2 > \gamma_{k+1} \geq 1$,令 $\beta=\gamma_{k+1}, x_{k+1} = x_{k+1}'$;

(c) 若 $\gamma_{k+1} \geq 2$,令 $\beta=2, x_{k+1} = x_{k+1}'$;

(5) 重新开始迭代,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:

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

(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 $\rho[p(x_k'), q]$ 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组合带宽 Mean Shift 的目标跟踪算法与单一带宽 Mean Shift 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 Mean Shift 算法的效果和实时性进行了对比。

在实验中选择核函数均为高斯核, 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 Mean Shift 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 Mean Shift 算法实验结果如图 2 所示, 其中圆点为迭代起始点, 白色实线为收敛路径, 青色矩形为收敛区域。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 Mean Shift 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。为了说明带宽序列的作

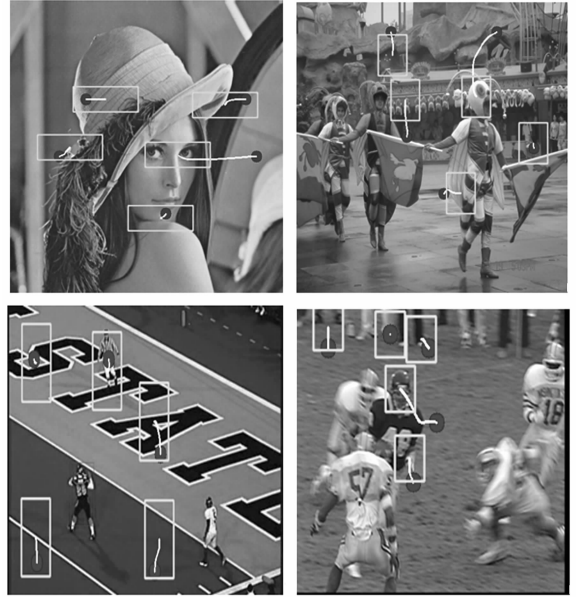


图 2 固定带宽 Mean Shift 收敛结果
Fig. 2 Convergences with fixed bandwidth Mean Shift

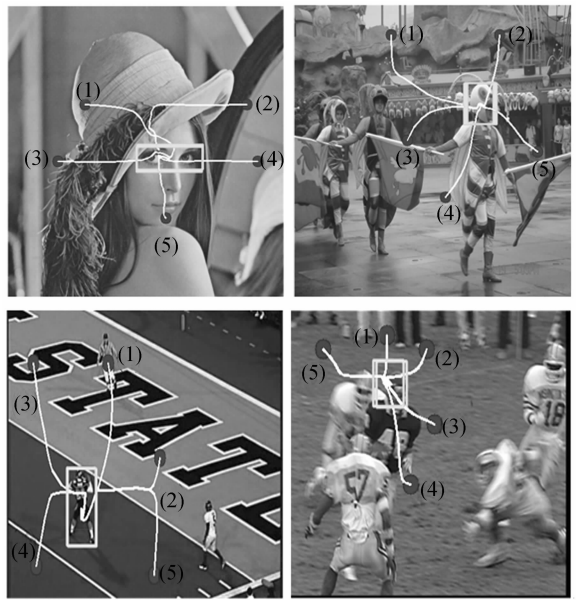





图 3 组合带宽 Mean Shift 收敛结果
Fig. 3 Convergences with multi-bandwidth Mean Shift

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。图中 X, Y 轴分别对应了图像的坐标。

采用多带宽跟踪后, 跟踪器的稳定性得到了

(a) h_2 相关系数(a) Bhattacharyya coefficient at h_2 (b) h_1 相关系数(b) Bhattacharyya coefficient at h_1 (c) h_0 相关系数(c) Bhattacharyya coefficient at h_0 图 4 h_2, h_1, h_0 带宽下的相关系数分布Fig. 4 Bhattacharyya coefficient distribution maps at bandwidth sequence of h_2, h_1, h_0

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,其中 TP 为测试点,每个测试点位置已在图 3

中标出。显然采用 over-relaxed 策略后迭代次数有了大幅度减少。

表 1 收敛次数对比

Tab. 1 Comparison of iterations

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

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 Mean Shift 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地克服这些问题。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 5 中比较了视频中第 121、131、159、167、173、189 帧的跟踪结果。图 5 中第一列为单一带宽均值迁移跟踪结果,第二列为本文提出的组合带宽搜索跟踪结果。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。

在 Sheng^[7]等提出的 over-relaxed 边界优化策略中,通过加速前后目标函数的变化增加或减少学习率,幅度 $\alpha=0.25$ 。在实际跟踪过程中,通常收敛条件有 2 个:(1)相关系数大于某个阈值 $rh \geq th_0$, (2) 相邻两次迭代步长小于某个阈值 $\|y_{k+1} - y_k\| < \epsilon$ 。在试验中,相关系数阈值 $th_0 = 0.95$,步长阈值 $\epsilon = 1$ 。定位实验中由于定位目标截取于被测图像,即被测图像理论上存在相关




图 5 头部跟踪实验对比(上列为固定带宽 Mean Shift, 下列为组合带宽 Mean Shift)

Fig. 5 Comparisons of head tracking between fixed bandwidth Mean Shift(top) and multi-bandwidth Mean Shift(bottom)

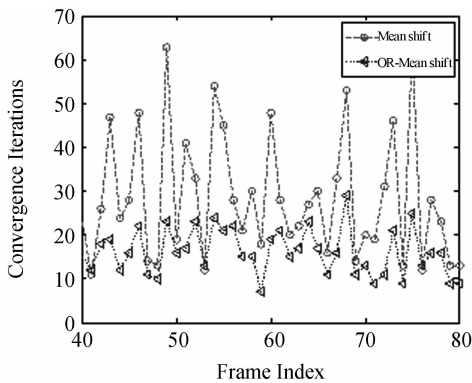


图 6 Mean Shift 与 OR-Mean Shift 迭代次数比较

Fig. 6 Comparisons of the iterations between Mean Shift and OR-Mean Shift



(a)固定学习率 over-relaxed

(a)Fixed learning rate over-relaxed




(b)自适应学习率 over-relaxed

(b)Adaptive learning rate over-relaxed

图 7 固定学习率 over-relaxed 与本文算法比较

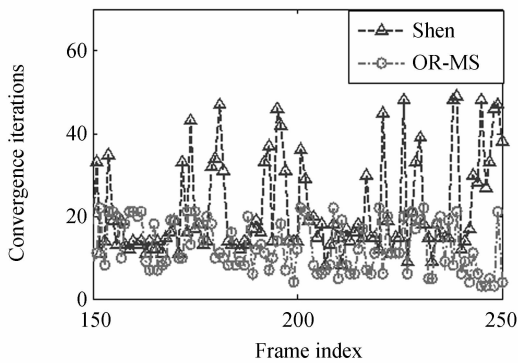
Fig. 7 Comparison of tracking results between Shen's and proposed algorithm

系数为 1 的位置,因此起作用的收敛条件往往是第一条。而在实际跟踪中,由于目标的表现特征在持续变化中,特征匹配程度有限,绝大部分时间里起作用的收敛条件是第二条。在 Shen 的方法中,若加速后的相关系数提高了,则在下一次跟踪中增加迭代步长,在概率密度变化平滑的区域确实是一种有效的策略,但在概率密度变化频繁,特别是在接近真实目标区域时,会导致学习率频繁抖动,最终在真实目标区域附近发生震荡。实验结果如图 7 所示。图中黑色矩形为迭代起始位置,灰色矩形为收敛位置,而白色矩形表示梯度上升过程。图 7(a)为固定增长率 over-relaxed 实验结果,迭代次数为 17,7(b)为本文算法实验结果,迭代次数为 10。显然,自适应学习率 over-relaxed 收敛过程更为平滑。在跟踪过程中收敛位置的相关系数曲线与两种 over-relaxed 策略所需要的迭代次数如图 8 所示。



(a) 相关系数曲线

(a) Bhattacharyya coefficients graph



(b) 迭代次数对比

(b) Comparison of convergence iterations

图 8 跟踪过程相关系数及收敛次数对比

Fig. 8 Bhattacharyya coefficients and convergence iterations during tracking procedure

7 结 论

为了解决传统 Mean Shift 算法中跟踪窗口容易受局部概率密度模式干扰的缺陷,提出一种基于组合带宽 Mean Shift 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,避开了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,并且当发生遮挡而造成目标短暂丢失时也具备一定的自我恢复能力。

在前人基础之上,将边界优化算法中的 over-relaxed 加速策略引入到目标跟踪中,实现了超线性收敛。为了克服固定增长率 over-relaxed 在接近最优模式时容易发生震荡的缺陷,提出了一种基于 Bhattacharyya 相关系数的自适应学习率 over-relaxed 算法,在接近概率密度峰值时将收敛速度降为线性收敛,获得了更为平滑的收敛路径,实验中迭代次数减少了 30%~70%。

参考文献:

- [1] 薛陈, 朱明, 陈爱华, 鲁棒的基于改进 Mean-shift 的目标跟踪[J]. 光学精密工程, 2010, 18(1): 234-239.
- XUE CH, ZHU M, CHEN A H. Robust object tracking based on improved Mean-shift algorithm [J]. *Opt. Precision Eng.*, 2010, 18(1): 234-239. (in Chinese)
- [2] 孟勃, 朱明. MSMC 跟踪算法在目标跟踪中的应用[J]. 光学精密工程, 2008, 16(1): 122-127.
- MENG B, ZHU M. Application of MSMC algorithm to visual tracking [J]. *Opt. Precision Eng.*, 2008, 16(1): 122-127. (in Chinese)
- [3] MAGGIO E, CAVALLARO A. Accurate appearance based bayesian tracking for maneuvering targets [J]. *Computer Vision and Image Understand-*

ing, 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 ZH, LIANG Y, ZHAO CH 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, TANG M. Accelerate convergence using dynamic mean shift [C]. *Proceedings of the 9th European Conference on Computer Vision, New York*, 2006: 257-268.
- [6] FASHING M, 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, BROOKS M J. A fast global kernel den-


sity mode seeking with application to localization and tracking [C]. *Proceedings of IEEE International Conference on Computer Vision, Los Alamitos*, 2005:1516-1523.

- [8] YIN Z Z, ROBERT 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*, 2008:1-8.
- [9] ELGAMMAL A, DURAI SWAMI R. Probabilistic tracking in joint feature-spatial spaces [C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C.*, 2004:790-797.


ceedings of IEEE Conference on Computer Vision and Pattern Recognition, Washington, D. C., 2004:790-797.

- [10] COMANICIU D, MEER P. Kernel-based object tracking [J]. *IEEE Trans. On Pattern Analysis and Machine Intelligence*, 2003,25(5):564-577.
- [11] CARREIRA PERPINAN 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.

作者简介:



周 斌(1984—),男,江西南昌人,博士研究生,2005年于西安邮电学院获得学士学位,主要从事图像处理、目标识别与跟踪等方面的研究。E-mail: giggsnet@163.com



沈 伟(1980—),男,山西太原人,讲师,2007年于北京理工大学获得博士学位,主要从事图像处理、嵌入式检测系统等方面的研究。E-mail: she_sw@bit.edu.cn

导师简介:



王军政(1964—),男,陕西宝鸡人,教授,博士生导师,1994年于北京理工大学获得博士学位,主要从事现代检测技术、光电跟踪系统及运动驱动与控制等方面的研究。E-mail: wangjz@bit.edu.cn

●下期预告

电活性聚合物的微型发电机

陈 明¹,林桂娟²,宋德朝²

(1. 同济大学 中德工程学院,上海 200092;2. 同济大学 机械工程学院,上海 200092)

为了利用可再生能源改变人类的能源结构,促进世界能源的可持续发展战略,通过实验分析电活性聚合物在静电场中机械能转换为电能的内部机理,对电活性聚合物发电原理进行研究。首先,在电活性聚合物定量试验研究的基础上,采用 Yeoh 模型、Mooney-Rivlin 模型和 Ogden 模型,建立了电活性聚合物变形特性的数学模型。其次,分析了材料在不同状态下的力学特性,构建了能量收集方程及运动学方程。最后,在电活性聚合物发电原理的基础上,采用丹佛斯生产的 DEAP 材料,建立了电活性聚合物风力发电机实验装置平台。实验结果表明:电活性聚合物在 10% 应变状态下,充电电压为 1 200 V 时,一次循环所收集的电能为 13.7 mJ。这些实验为电活性聚合物致动器、传感器和微型发电机的研究奠定了理论基础。