

基于偏最小二乘分析的双模粒子滤波目标跟踪

谢英红^{1,2}, 吴成东¹

(1. 东北大学 信息科学与工程学院, 沈阳 110004; 2. 沈阳大学 信息工程学院, 沈阳 110044)

摘要: 针对在复杂背景下, 基于主成分分析(PCA)的目标跟踪方法准确率较低的问题, 使用偏最小二乘分析, 提出一种双模粒子滤波的跟踪算法. 首先采用偏最小二乘分析对目标区域建模, 作为观测模型; 然后利用仿射变换描述目标的形变过程, 分别在李群及其切向量空间上建立双模的动态模型; 最后结合特征空间更新策略, 使用粒子滤波实现目标跟踪. 实验表明, 所提出的算法能够有效滤除背景噪声, 跟踪结果稳定且准确.

关键词: 目标跟踪; 偏最小二乘; 黎曼流形; 粒子滤波; 双模

中图分类号: TP391

文献标志码: A

Tracking objects based on partial least squares analysis using particle filtering with dual models

XIE Ying-hong^{1,2}, WU Cheng-dong¹

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 2. School of Information Engineering, Shenyang University, Shenyang 110044, China. Correspondent: XIE Ying-hong, E-mail: xieyinghong@163.com)

Abstract: For the problem that the object tracking algorithm using principal components analysis(PCA) has low accuracy in a complex environment, based on the partial least squares analysis, an object tracking algorithm is proposed by using particle filtering with dual models. Firstly, the model of object region is built by the partial least squares analysis, which is applied as the observation model. Then, the dynamic model with dual models is built on Lie group and the corresponding tangent vector space respectively, with the describing the object deformation process by affine transformation. Finally, combining with the update strategy for feature space, the object tracking algorithm is realized by particle filtering. Experiments show that the tracking results are stable and accurate, and the proposed algorithm can effectively filter out the background noise.

Key words: object tracking; partial least squares; Riemannian manifold; particle filtering; dual model

0 引言

粒子滤波(PF)是一种贝叶斯状态滤波算法, 基本思想是利用一组在状态空间中传播的随机样本近似后验概率分布, 以样本均值代替积分运算, 从而获得状态最小方差估计过程. 在目标跟踪领域, 由于粒子滤波非线性且不限定噪声为高斯噪声, 目前很多文献^[1-8]使用粒子滤波在线学习的方法构建目标跟踪框架, 特别是将粒子滤波与仿射变换流形相结合构建跟踪框架已成为各种跟踪算法研究的热点. 文献[1]使用粒子滤波有效地处理2-D仿射变换的目标跟踪问题. 文献[2]利用仿射形变参数分布在低维流形上这一特点, 使用仿射李群建立粒子滤波的状态模型, 实

现了形变目标的跟踪. 文献[4]提出了一种在黎曼流形上的渐增协方差张量的跟踪方法, 利用仿射变换描绘目标的形变过程, 融合了粒子滤波框架, 能够更好地去除背景干扰, 并且渐增地学习低维的协方差张量, 能够实现实时跟踪. 文献[5-6]提出了利用黎曼流形几何结构和贝叶斯框架下的测地线方法构建双粒子滤波器, 同样利用仿射变换描绘目标的形变过程, 实现对可视和红外目标的跟踪.

在目标跟踪过程中, 可能发生光照变化、遮挡和非刚体目标的形变等目标表现的变化, 因此, 构建合理、准确且鲁棒性好的目标表征模型是目标跟踪算法的主要研究内容之一. 从1998年至今, 在视觉目标跟

收稿日期: 2013-09-12; 修回日期: 2013-12-10.

基金项目: 国家自然科学基金项目(61273078).

作者简介: 谢英红(1976-), 女, 讲师, 博士生, 从事图像处理、目标跟踪与识别的研究; 吴成东(1960-), 男, 教授, 博士生导师, 从事图像智能处理、机器人控制等研究.

踪中包括灰度、颜色、纹理等多种目标区域特征,但这些特征很难实现对光照和遮挡变化下的稳定跟踪.近年来, Porikli 等^[1,9-11]使用区域协方差作为目标区域描述子,其优势就是克服某一种或某几种特征失效引起跟踪失败的缺陷,即使在光照变化、遮挡的情况下,跟踪仍能继续.但是采用固定模板跟踪的方法在目标经历剧烈光照变化或遮挡等情况下,跟踪鲁棒性会变差. PCA 方法采用多个模板的线性组合表征目标,在线更新特征空间,使得所构建的目标特征空间能够随时反映目标表面的变化,而且无须离线的学习训练过程,相对上述算法更具适用性^[12].当目标的姿态和光照同时剧烈变化时, PCA 算法所构建的特征基不能很快体现这些新变化,导致跟偏目标,并最终跟丢目标,且上述方法没有处理目标遮挡等异常情况,使得目标的特征空间中可能参杂异常信息,从而使特征空间无法准确地表征目标,导致在背景复杂情况下跟踪结果不稳定^[13-14].

考虑到偏最小二乘法集成了主成分分析、典型相关分析和多元线性回归分析3种分析方法的优点^[15-16],它与主成分分析法都试图提取出反映数据变异的最大信息.在主成分分析中,主元的选取以最大限度地概括自变量空间数据的变化信息为准则,并没有考虑主元对于因变量的解释作用,而未被选取的次要主元有可能包含对回归有益的信息,已被选取的主元也有可能包含对于回归无益的噪声.偏最小二乘分析不仅能够有效地克服普通最小二乘回归的共线性问题,而且将多元回归问题转化为若干个一元回归问题,具有较好的鲁棒性和预测稳定性.应用到图像跟踪领域,该模型不但能够有效识别目标区域信息,同时考虑了目标的背景信息,可以有效地滤除背景噪声.鉴于此,本文将粒子滤波与偏最小二乘分析相结合,提出了基于偏最小二乘分析的双模粒子滤波目标跟踪算法.使用偏最小二乘分析来表征目标区域特征,构建目标的特征空间.利用仿射变换表示目标的形变过程,分别在李群及其切空间上建立双动态粒子滤波模型.同时构建了有效的目标特征空间更新策略,使得离群点信息被隔离到特征空间外,提高了目标在经历复杂表观变化或是背景变化时跟踪效果的准确性.

1 偏最小二乘目标表征

偏最小二乘(PLS)分析是一种新型的多元统计数据分析方法,主要研究多因变量对多自变量的回归建模,特别是当各变量内部高度线性相关时,用偏最小二乘回归法更有效.

定义一个 m 维的向量 x 和与其对应的标签变量 y .本文中, x 为目标区域的特征向量, y 为对应的标签.设 $X \in R^{N \times M}$ 为 N 个图像特征向量的集合, $Y \in$

R^N 为对应标签的集合.给定变量对 $\{x_i, y_i\}, i = 1, 2, \dots, N, x \in R^N, y \in R^N$, PLS 回归是利用潜在的空间映射建立 x 和 y 的关系模型.这里简要回顾一下 PLS 分析方法^[15-16]. PLS 分解 X 和 Y 如下:

$$X = TP^T + E, Y = UQ^T + F. \quad (1)$$

其中: T 和 $U (N \times p, p < d)$ 为本征向量, $P (d \times p)$ 和 $Q (1 \times p)$ 为载荷向量, $E (d \times N)$ 和 $F (1 \times N)$ 为残差矩阵. PLS 通常通过非线性迭代最小二乘方法(NIPALS)实现^[15],该方法构建权重向量的集合 $W = \{w_1, w_2, \dots, w_n\}$, 满足

$$\max [\text{cov}(t_i, u_i)]^2 = \max_{|w_i|=1} [\text{cov}(Xw_i, Y)]^2. \quad (2)$$

其中: t_i 和 u_i 分别为向量 T 和 U 的第 i 列, $\text{cov}(t_i, u_i)$ 为本征向量 t_i 与 u_i 的样本协方差,最大化本征向量空间的样本协方差相当于最大化同一空间的区分度. NIPALS 算法等效于迭代计算出如下等式的主要特征向量:

$$[X^T y y^T X] w_i = \lambda W. \quad (3)$$

载荷向量 (P 和 Q 的第 i 列) 计算为

$$p_i = \frac{X^T t_i}{t_i^T t_i}, \quad (4)$$

$$q_i = \frac{Y^T u_i}{u_i^T u_i}. \quad (5)$$

提取出 t_i 和 u_i 后, 矩阵 X 和 Y 为

$$X \leftarrow X - t_i p_i^T, Y \leftarrow Y - u_i q_i^T. \quad (6)$$

至此, 去除了 t_i 和 u_i 在 X 和 Y 中的信息. 重复以上过程, 直到残差矩阵足够小或是得到了预定义数量的权重向量.

上述 PLS 分析表明, 学习一个低维的空间, 使得不同的观测数据集合具有更大的相关度, 能够更好地将目标图像从背景中分离出来, 有效滤除背景干扰. 本文采用偏最小二乘分析方法建立目标的表观模型. 对于给定的图像区域, 选取各个像素点的灰度矩阵作为特征向量, 令

$$X_t =$$

$$[X_1^p, X_2^p, \dots, X_{N_p}^p, X_1^n, X_2^n, \dots, X_{N_n}^n] \in R^{N \times m}$$

表示样本空间特征向量的集合, 其中每个分量表示一个对应区域的灰度矩阵; $y = [1, 1, \dots, 1, 0, 0, \dots, 0] \in R^{N \times 1}$ 表示对应的标签; N_p 为正样本数量, N_n 为负样本数量, 样本总数 $N = N_p + N_n$. 使用最小二乘回归得到对应样本的权重向量 W , 计算出正样本均值 \bar{x}^p 和正负样本均值 \bar{x} , 建立目标表观模型 $A_t = [\bar{x}^p, \bar{x}, W]$. 在跟踪过程中, 建立目标表观模型的集合 $A = \{A_1, A_2, \dots, A_k\}$ 作为目标的特征空间, k 为集合中元素的个数, 表示当前模型空间中目标表观向量的数量, 在跟踪过程中不断更新目标的表征空间.

本文算法中,对于第1帧图像,手动标记出目标区域,该区域对应的灰度向量为正样本 x_1 . 此外,对图像实行微小的扰动,产生虚拟数据,作为其余的正样本向量. 负样本向量由 $\alpha < \|I_n(x, y) - I(x, y)\| < \beta$ 的圆形区域随机取得, $I_n(x, y)$ 为负样本的中心坐标, $I(x, y)$ 为所指定的正样本的中心坐标. 对于第 j 帧图像,假定粒子滤波所产生的每一个状态向量为目标区域,用与第1帧同样的方法确定其正、负样本,构建特征向量的集合

$$X_t =$$

$$[X_1^p, X_2^p, \dots, X_{N_p}^p, X_1^n, X_2^n, \dots, X_{N_n}^n] \in R^{N \times m}$$

和对应的标签向量

$$y = [1, 1, \dots, 1, 0, 0, \dots, 0] \in R^{N \times 1},$$

并计算得到对应的表观模型 $A_t = [\bar{x}^p, \bar{x}, W]$. 本文算法中,负样本数量为40.

表观模型 $A_t = [\bar{x}^p, \bar{x}, W]$ 与 $A = [\bar{x}^p, \bar{x}', W']$ 之间的距离定义为

$$d(A_t, A) = \|W'^T(\bar{x} - \bar{x}') - W^T(\bar{x}^p - \bar{x}'^p)\|_2^2. \quad (7)$$

2 跟踪模型

2.1 粒子滤波

用状态变量 S_t 描述目标在 t 时刻的仿射变换参数,目标跟踪的目的是通过序列观测图像 $I_{1:t} = \{I_1, I_2, \dots, I_t\}$ 估计当前状态 S_t . 由贝叶斯定理有

$$p(S_t | I_{1:t-1}) = \int p(S_t | S_{t-1}) p(S_{t-1} | I_{1:t-1}) dS_{t-1}, \quad (8)$$

$$p(S_t | I_{1:t}) = \frac{p(I_t | S_t) p(S_t | I_{1:t-1})}{p(I_t | I_{1:t-1})}. \quad (9)$$

式(8)称为预测方程,表示目标状态转移的概率模型. 式(9)称为更新方程. 跟踪过程描述为:若已知 $t-1$ 时刻目标状态的概率密度 $p(S_{t-1} | I_{1:t-1})$, 则根据状态转移的概率模型 $p(S_t | S_{t-1})$ 和观测 I_t , 递归地计算 t 时刻目标状态的后验概率密度 $p(S_t | I_{1:t-1})$.

粒子滤波器通过蒙特卡罗模拟对贝叶斯时序滤波器进行实现,粒子(样本)是指用一个参数集合定义目标的状态,多个离散的粒子可表示目标属性的分布,实现目标跟踪. 其思想是用一个随机采样集合(每个样本带有对应的权值)近似表示未知状态的后验概率分布. 如果样本数足够大,则该样本集合的分布可认为等同后验概率分布.

用 $\{S_{0:k}^i, w_k^i\}_{i=1}^N$ 表示系统后验概率密度函数 $p(S_{0:k} | I_{1:k})$ 的粒子集合. 其中: $\{S_{0:k}^i, i = 1, 2, \dots, N\}$ 为支持样本集; $\{w_k^i, i = 1, 2, \dots, N\}$ 为相应的权值,且满足 $\sum_{i=1}^N w_k^i = 1$; $S_{0:k} = \{S_j, j = 0, 1, \dots, k\}$ 为时刻 k 系统所有状态的集合. 因此时刻 k 的后验密度可

以近似表示为

$$p(S_{0:k} | I_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(S_{0:k} - S_{0:k}^i). \quad (10)$$

2.2 李群结构下的双动态模型

李群和微分几何构成本文所提算法的理论基础,详细内容参见文献[17-18]. 设 G 为李群, X 和 Y 分别为李群上的一点. 李群既是一个群,又是光滑流形,其群上的乘法运算和逆运算

$$G \times G \rightarrow G, (X, Y) \rightarrow XY,$$

$$G \rightarrow G, X \rightarrow X^{-1} \quad (11)$$

是光滑映射. 李群元素 G 的邻接点可以用其切空间进行描述,单位元处的切空间构成李代数, $n \times n$ 阶非奇异方阵的集合在矩阵乘法下构成矩阵李群.

本文使用仿射变换表示目标变换模型,仿射变换矩阵

$$T(r) = \begin{bmatrix} r_1 & r_2 & r_5 \\ r_3 & r_4 & r_6 \\ 0 & 0 & 1 \end{bmatrix}$$

具有李群结构. 与此仿射李群 $GA(2)$ 对应的李代数为 $ga(2)$, 矩阵 $G_i (\forall i \in \{1, 2, \dots, 6\})$ 为 $GA(2)$ 的生成元, $G_i (\forall i \in \{1, 2, \dots, 6\})$ 构成 $ga(2)$ 的基. 对于 $GA(2)$, 生成元如下:

$$\begin{aligned} G_1 &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, G_2 = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \\ G_3 &= \begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, G_4 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, \\ G_5 &= \begin{bmatrix} 0 & 0 & 1 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}, G_6 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}. \end{aligned} \quad (12)$$

对于矩阵李群,黎曼距离由矩阵对数操作定义为

$$d'(X, Y) = \|\log(YX^{-1})\|, \quad (13)$$

其中 X 和 Y 为矩阵李群元素.

给定 N 个对称正定有限矩阵 $\{X_i\}_{i=1}^N$, 其内蕴均值定义为

$$\mu^* = \exp\left(\frac{1}{N} \sum_{i=1}^N \log(X_i)\right). \quad (14)$$

在目标跟踪过程中,仿射变换用来描述目标的几何形变过程,因为仿射变换为正定对称流形,是一个李群,不再服从欧式空间. 目标在相邻帧之间的变化可以看作是仿射变换矩阵对应的点在黎曼流形上的移动,建立动态模型的基本思想是找到流形上相邻两点间的转换关系,本文算法使用流形上点的切向量描

述这种关系. 分别在黎曼流形和切空间上建立双动态模型, 有

$$\begin{aligned} S_t &= S_{t-1} \exp(v_{t-1}), \\ v_t &= a(v_{t-1} - v_{t-2}) + \mu_{t-1}. \end{aligned} \quad (15)$$

其中: 向量 $S_t = [x_1, x_2, x_3, x_4, x_5, x_6]^T$ 为目标几何形变的仿射变换参数; v_t 为 S_{t-1} 到 S_t 的速度向量, 表示目标的运动, 即在流形上沿状态 S_t 的切向量, 设服从高斯分布; $\mu_{1:t}$ 为高斯白噪声; a 为一阶自回归系数.

2.3 观测模型

在跟踪过程中, 每一时刻预测的新状态均需要利用观测数据对其进行修正, 因此需要测量观测数据与模板的相似性来度量该状态下此样本是真正目标的概率. 设 $p(I_t|S_t)$ 为 I_t 在状态 S_t 下的观测, 有

$$p(I_t|S_t) \propto \exp(-\lambda \|d^2(A_t^i, A)\|^2). \quad (16)$$

其中: A_t^i 为当前图像区域的特征向量模型, A 为当前目标表观的模板. 粒子权重计算如下:

$$w_t^j = \exp(-\lambda \|d^2(A_t^i, A)\|^2). \quad (17)$$

权重归一化为

$$w_t^j = w_t^j / \sum_{j=1}^M w_t^j. \quad (18)$$

3 跟踪算法和特征空间更新策略

3.1 目标特征空间更新策略

跟踪过程中可能发生光照变化、遮挡和非刚体目标的形变等目标表观变化, 因此需要建立一种自适应的更新策略, 实时更新目标特征空间, 以达到稳定的跟踪效果. 本文算法利用特征向量之间的距离描述对应图像区域之间的相似性. 设当前帧的特征向量与特征空间各个特征向量距离的最小值为 d_s , 当 d_s 大于某个给定的最大值阈值 thresmax 时 (本文选取 thresmax 为 $\|X_t\|^2/4$), 表明该帧图像被严重遮挡或失真. 此时为了保证特征空间信息的准确性, 不更新特征空间; 否则, 分以下两种情况更新模板集合:

1) 当前特征空间中向量的个数小于预先规定的数量时, 直接将当前帧的特征向量加入到该特征空间集合中;

2) 否则, 用当前帧的特征向量代替特征空间中具有最大距离值的特征向量.

3.2 跟踪算法

本文使用偏最小二乘分析表征目标区域, 利用仿射变换描述目标的形变, 分别在李群和李代数上建立双模粒子滤波器以实现目标的稳定跟踪. 具体跟踪算法如下.

输入: 目标初始状态 $S_0 = [1; 0; 0; 1; 0; 0]$, $v_1 = 1$, 特征空间中特征向量的数量 g , 初始化特征空间 A

$= \{ \}$, 待跟踪视频图像序列;

输出: 目标估计状态 S_t ;

初始化: 由目标初始先验分布 $p(S_0)$ 产生 M 个采样 $\{S_0^i, i = 1, 2, \dots, M\}$, 并置采样粒子的初始权值 $\omega_0^i = 1/M$, 初始化模板集合 $A = \{ \}$.

Step 1: 手动确定第1帧图像的目标区域, 计算对应的 $A_1 = [\bar{x}, \bar{x}, W]$, 并入到特征空间 A 中.

Step 2: 对于第 t 帧图像, 根据式 (15) 从条件先验中采样 $\{\tilde{S}_t^i, i = 1, 2, \dots, M\}$.

Step 3: 对于每个采样对应的图像区域, 生成 N_p 个正样本, N_n 个负样本, 计算对应的 A_t^i , 由式 (17) 和 (18) 计算每个采样粒子的权值 w_t^j .

Step 4: 由

$$S_t = \exp\left(\frac{1}{M} \sum_{i=1}^M \log(w_t^i S_t^i)\right)$$

计算采样内蕴均值即为目标的估计状态 S_t .

Step 5: 由目标特征空间的更新策略更新特征空间 A .

Step 6: 令 $t = t + 1$, 转至 Step 2.

4 实验结果和分析

以本文算法为核心, 采用 Matlab 2007 实现, 通过与采用 PCA 的增量学习跟踪算法 (IVT)^[13] 对比, 验证本文所提出算法的有效性. 两种方法在相同的实验配置下比较性能. 对于每1个跟踪序列, 第1帧图像的边界框手动设置, 采样粒子数为 300, 自回归系数 $a = 1$.

为了比较本文算法与 IVT 算法在跟踪复杂背景下的图像序列的性能差异, 选用背景较为复杂情况下的图像序列. 对于每一帧, 计算跟踪到的目标区域与真实目标区域的中心点坐标的欧式距离误差. 设 (x_t', y_t') 为 t 时刻跟踪到的目标区域的中心点坐标, (x_t, y_t) 为 t 时刻真实目标区域的中心点坐标 (实验中, 真实目标的中心点位置手动标注), 则定义 t 时刻欧氏距离误差为

$$\text{DisError}_t = \sqrt{(x_t' - x_t)^2 + (y_t' - y_t)^2}. \quad (19)$$


计算平均面积误差比, 定义为

$$\text{SimilarRatio} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n \left(\frac{|S_{\text{track},j} - S_{\text{true},j}|}{S_{\text{true},j}} \right). \quad (20)$$

其中: $S_{\text{track},j}$ 为第 j 帧中跟踪到的目标区域面积; $S_{\text{true},j}$ 为第 j 帧中目标的真实面积; m 为同一个视频序列的实验次数, 本文所有实验重复执行 20 次; n 为视频序列的总帧数.

第1组标准测试图像序列 car11, 目标经历了严重的光照变化. 初始参数设置为: 目标中心点坐标 (89, 140), 宽 30 像素, 高 25 像素, 旋转弧度为 0, 跟踪结果

如图 1 所示. 由图 1 可见, 两种算法的跟踪结果相似, 表明 IVT 算法和本文算法都具有对光照变换的不敏感性.




(a) IVT 算法跟踪结果




(b) 本文算法跟踪结果

图 1 图像序列 car11 跟踪结果

第 2 组测试图像序列 skating, 目标经历了复杂的背景变化. 初始参数设置如下: 目标中心点坐标 (328, 122), 宽 50 像素, 高 130 像素, 旋转弧度为 0. 在该组测试序列中, 目标在第 60 帧开始旋转平移, 同时, 在相同的位置出现了与目标视觉上相似的背景. 跟踪结果如图 2 所示. 图 2(a) 表明, 从第 63 帧开始, IVT 算法丢失了跟踪目标. 图 2(b) 表明, 本文算法跟踪结果



(a) IVT 算法跟踪结果




(b) 本文算法跟踪结果


图 2 图像序列 skating 跟踪结果

稳定. 这是由于本文算法的特征空间的模板中包含负样本信息, 能够有效滤除背景干扰, 使得跟踪结果更稳定.

第 3 组标准测试图像序列 sylv, 目标经历了大尺度的位姿变化. 初始参数设置如下: 目标中心点坐标 (145, 81), 宽 53 像素, 高 53 像素, 旋转弧度为 -0.2 , 跟踪结果如图 3 所示. 图 3(a) 表明, 从第 610 帧开始, IVT 算法逐渐丢失目标. 图 3(b) 表明, 本文算法跟踪结果稳定. 这是由于本算法采用的双动态模型能更有效地表示目标的几何变换.




(a) IVT 算法跟踪结果



(b) 本文算法跟踪结果

图 3 图像序列 sylv 跟踪结果



(a) IVT 算法跟踪结果



(b) 本文算法跟踪结果

图 4 图像序列 jogging 跟踪结果

第 4 组标准测试图像序列 jogging, 初始参数设置为: 目标中心点坐标 (124,144), 宽 28 像素, 高 104 像素, 旋转弧度为 0. 该序列中目标经历了严重的遮挡, 跟踪结果如图 4 所示. 图 4(a) 表明, IVT 算法在目标被遮挡后无法重新跟踪到目标. 图 4(b) 表明, 本文算法能够重新捕获目标. 这是因为本文算法的目标更新策略, 使得当某帧图像被严重遮挡或失真时, 不更新特征空间, 保证了特征空间信息的准确性.

图 5 为两种算法的距离误差, 表 1 为 20 次实验面积误差比的平均值. 由图 5 和表 1 可见, 在跟踪复杂背景的视频序列时, 本文所提出算法的跟踪性能优于 IVT 算法. 这是因为 IVT 算法使用的主成分分析是通过一种无监督的学习方法为子空间建模, 在复杂背景

下, 难以实现稳定跟踪. 而偏最小二乘分析通过最大化特征向量与对应的标签之间协方差的方法计算权重向量, 使得建立的目标区域表征具有更大的区分度, 且本文算法在构建特征空间模型时考虑了负样本信息, 能够有效地滤除背景噪声. 另外, 本文的粒子滤波算法充分利用了仿射变换参数的李群结构, 将状态空间模型置于流形上, 直接在低维流形上实现测地线状态采样, 降低了目标跟踪系数的维数, 提高了跟踪算法的性能. 另外, 本文采用的特征空间更新策略, 有效屏蔽了目标遮挡时跟踪到的特征模型, 使得特征空间中的模型更加准确.

综上, 在复杂背景下或目标经历严重遮挡的情况下, 采用最小二乘回归方法表征目标区域特征的方法具有更准确、更稳定的跟踪效果.

本文算法的时间复杂度为 $O(N)$, 其中 N 为所用粒子个数. 当 $N = 300$ 时, 两种算法跟踪每一帧的平均时间如表 2 所示. 虽然目前还达不到实时性要求, 但希望在后续工作中, 通过采用更高效的设计环境和改进算法执行效率, 取得更快的跟踪速度.

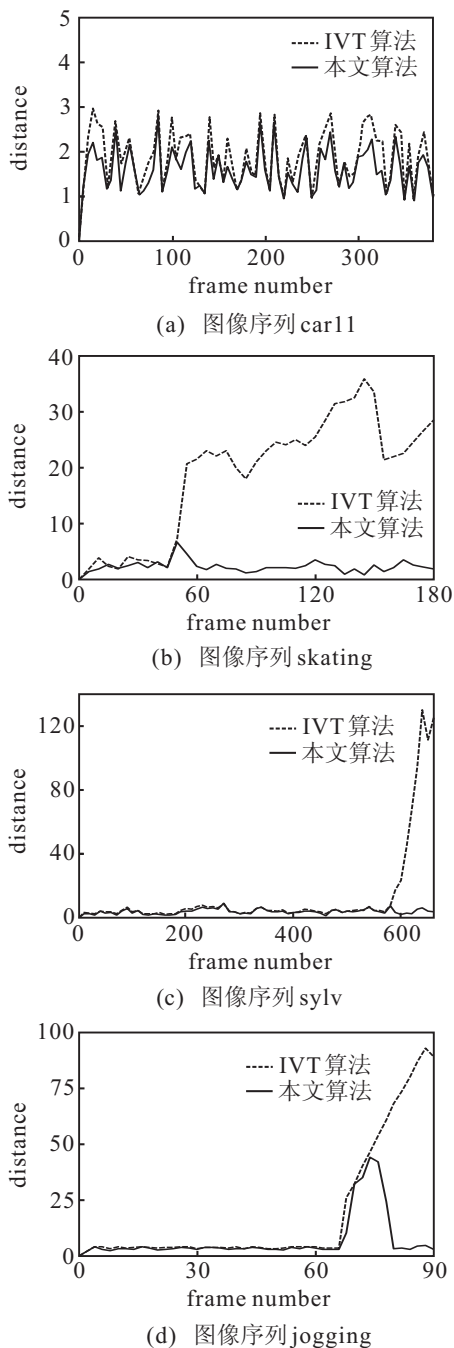


图 5 跟踪到的区域与真实目标区域的距离比较

表 1 两种算法平均距离误差和面积误差比较

| | 算法 | Car11 | skating | sylv | jogging |
|------|--------|---------|----------|----------|----------|
| 距离误差 | IVT 算法 | 1.822 1 | 18.586 5 | 12.731 3 | 17.699 0 |
| | 本文算法 | 1.591 1 | 2.213 5 | 3.596 2 | 6.787 5 |
| 面积误差 | IVT 算法 | 0.085 | 0.106 | 0.112 | 0.108 |
| | 本文算法 | 0.078 | 0.096 | 0.100 | 0.095 |

表 2 平均每帧耗时比较

| 算法 | Car11 | skating | sylv | jogging |
|--------|----------|----------|----------|----------|
| IVT 算法 | 0.349 49 | 0.362 93 | 0.337 07 | 0.337 31 |
| 本文算法 | 0.181 12 | 0.243 05 | 0.186 71 | 0.199 90 |

5 结 论

本文提出了基于偏最小二乘分析的双模粒子滤波目标跟踪算法. 采用偏最小二乘分析法构建特征空间, 具有较好的鲁棒性和预测稳定性. 双动态模型有效利用李代数及其切空间的转换关系作为粒子滤波的参数度量, 更加准确地描述了目标的几何形变过程. 结合目标特征空间更新策略, 使得特征空间能够有效屏蔽目标遮挡时的特征模型, 减少目标特征空间中目标信息的异常状态, 提高了模板的精确性, 从而提高了跟踪的准确性. 实验结果表明, 跟踪目标在复杂背景下或经历遮挡等情况下, 跟踪效果稳定且准确. 本文只考虑了单目标的跟踪, 如何实现多目标的稳定跟踪是下一步的研究重点.

参考文献(References)

[1] Wu Y, Wu B, Liu J, et al. Probabilistic tracking on riemannian manifolds[C]. The 19th Int Conf on Pattern Recognition. Florida, 2008: 1-4.

- [2] Kwon J H, Lee K M, Par F C. Visual tracking via geometric particle filtering on the affine group with optimal importance functions[C]. IEEE Conf on Computer Vision and Pattern Recognition. Seoul, 2009: 991-998.
- [3] 朱明清, 王智灵, 陈宗海. 基于灰色预测模型和粒子滤波的视觉目标跟踪算法[J]. 控制与决策, 2012, 27(1): 53-57
(Zhu M Q, Wang Z L, Chen Z H. Visual tracking algorithm based on grey prediction model and particle filter[J]. Control and Decision, 2012, 27(1): 53-57.)
- [4] Liu Y P, Li G W, Shi Z L. Covariance tracking via geometric particle filtering[J]. J on Advances in Signal Processing, 2010: 1-9.
- [5] Wu Y, Cheng J, Wang J Q. Real-time probabilistic covariance tracking with efficient model update[J]. IEEE Trans on Image Processing, 2012, 21(5): 2824-2837.
- [6] Khan Z H, Gu I Y H. Tracking visual and infrared objects using joint riemannian manifold appearance and affine shape modeling[C]. IEEE Int Conf on Computer Vision Workshops. Gothenburg, 2011: 1847-1854.
- [7] Wang Q, Xu W L. Object tracking via partial least squares analysis[J]. IEEE Trans on Image Processing, 2012, 21(10): 4454-4465.
- [8] 陈志敏, 薄煜明, 吴盘龙, 等. 基于自适应粒子群优化的新型粒子滤波在目标跟踪中的应用[J]. 控制与决策, 2013, 28(2): 193-200.
(Chen Z M, Bo Y M, Wu P L, et al. Novel particle filter algorithm based on adaptive particle swarm optimization and its application to radar target tracking[J]. Control and Decision, 2013, 28(2): 193-200.)
- [9] Porikli F, Tuzel O, Meer P. Covariance tracking using model update based on Lie algebra[C]. IEEE Computer Society Conf on Computer Vision and Pattern Recognition. New York, 2006: 728-735.
- [10] Li G W, Liu Y P, Yin J. Target tracking with feature covariance based on an improved lie group structure[J]. Chinese J of Scientific Instrument, 2010, 31(1): 111-116.
- [11] Khan Z H, Gu I Y. Bayesian online learning on riemannian manifolds using a dual model with applications to video object tracking[C]. IEEE Int Conf on Computer Vision Workshops. Gothenburg, 2011: 1042-1409.
- [12] Wu Y, Wu B, Liu J, et al. Probabilistic tracking on riemannian manifolds[C]. The 19th Int Conf on Pattern Recognition. Florida, 2008: 1-4.
- [13] Ross D, Lim J, Lim R S, et al. Incremental learning for robust visual tracking[J]. Int J of Computer Vision, 2008, 77(1): 125-141.
- [14] Cai H, Li N, Zhao H J. The tracking approach for small target with complex background based on spectral features[C]. The 8th IEEE Int Symposium on Instrumentation and Control Technology. London, 2012: 55-60.
- [15] 陆文, 蔡敬菊. 基于鲁棒子空间学习的粒子滤波跟踪算法[J]. 计算机应用研究, 2011, 28(9): 3579-3584.
(Lu W, Cai J J. Object tracking using robust subspace learning in particle filter[J]. Application Research of Computers, 2011, 28(9): 3579-3584.)
- [16] Roman R, Nicole K. Overview and recent advances in partial least squares[J]. Latent Structures Feature Selection, 2006, 3940: 34-51.
- [17] Srinivasan B V, Zotkin D N, Duraiswami R. A partial least squares framework for speaker recognition[C]. The IEEE Int Conf on Acoustics, Speech and Signal Processing. Prague, 2011: 5276-5279.
- [18] Berger M. A panoramic view of Riemannian geometry[M]. Berlin: Springer, 2003: 161-232.
- [19] Hall B C. Lie algebras and representations: An elementary introduction[M]. New York: Springer, 2003: 3-58.

(责任编辑: 郑晓蕾)