

# 基于主分量寻踪的鲁棒视觉跟踪

袁广林<sup>1</sup>, 薛模根<sup>2</sup>

(1. 解放军陆军军官学院十一系, 安徽合肥 230031; 2. 解放军陆军军官学院科研部, 安徽合肥 230031)

**摘要:** 传统子空间跟踪易受到模型漂移的影响而导致跟踪失败. 针对此问题, 本文提出一种基于主分量寻踪的鲁棒视觉跟踪方法. 该方法以多个模板张成的子空间作为目标表观模型, 利用主分量寻踪求解候选目标的误差分量, 在粒子滤波框架下利用候选目标的误差分量估计最优状态参数. 为了适应目标表观变化并克服模型漂移, 本文提出一种模板更新方法. 当跟踪结果与目标模板相似时, 该方法利用跟踪结果更新目标模板, 否则利用跟踪结果的低秩分量更新目标模板. 在多个具有挑战性的图像序列上的实验结果表明: 与现有跟踪方法相比, 文中的跟踪方法具有较优的跟踪性能.

**关键词:** 视觉跟踪; 模型更新; 主分量寻踪; 稀疏分量

**中图分类号:** TP391.4      **文献标识码:** A      **文章编号:** 0372-2112 (2015)03-0417-07

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2015.03.001

## Robust Visual Tracking via Principal Component Pursuit

YUAN Guang-lin<sup>1</sup>, XUE Mo-gen<sup>2</sup>

(1. Eleventh Department, Army Officer Academy of PLA, Hefei, Anhui 23003, China;

2. Department of Scientific Research, Army Officer Academy of PLA, Hefei, Anhui 230031, China)

**Abstract:** The traditional subspaces based visual trackers are prone to model drifting. To deal with this problem, we propose a robust visual tracking method based on principal component pursuit. The proposed method represents objects with subspaces spanned by multiple templates, and finds error components of target candidates via principal component pursuit. The optimal state parameters are estimated by the error components of object candidates in particle filter framework. To adapt to changes of object appearance and avoid model drifting, a template update method is proposed. The proposed method updates the template set using tracking result when the tracking result is very similar to the templates; otherwise, it updates the template library with low-rank component corresponding to the tracking result. The experimental results on several challenging sequences show that the proposed method has better performance than that of the state-of-the-art tracker.

**Key words:** visual tracking; model update; principal component pursuit; sparse component

## 1 引言

视觉跟踪是计算机视觉领域中的基础研究问题, 其目标是利用图像序列估计目标的状态, 它在智能监控、人机交互、机器人导航和视觉制导等领域有重要的应用价值. 视觉跟踪的主要难题是复杂背景, 以及目标遮挡、光照变化和视角变化等因素引起的目标表观变化. 针对这些难题, 尽管已经提出了一些跟踪方法<sup>[1~3]</sup>, 但是这些问题并没有解决, 视觉跟踪仍然是计算机视觉领域中研究的热点.

受到主分量分析 (Principal Component Analysis, PCA) 在人脸识别中应用的启发, 1998 年 Black 和 Jepson<sup>[4]</sup> 提

出了基于 PCA 的子空间跟踪. 该方法基于子空间常量假设, 以候选目标的重建误差为目标函数, 利用梯度下降法跟踪目标. 以子空间常量为假设, 使其不能适应目标表观变化. 为此, Lim 等人<sup>[1]</sup> 提出一种增量子空间学习跟踪 (IVT 跟踪), 该方法利用增量子空间学习更新特征基, 适应了目标表观变化. 为了克服 IVT 跟踪易于丢失图像结构和邻域信息, 从而降低跟踪精度的不足, 文献<sup>[5]</sup> 提出一种增量张量子空间跟踪方法. 增量子空间跟踪<sup>[1,5]</sup> 以观测噪声符合高斯分布为假设, 导致其对目标遮挡的鲁棒性较差, 利用跟踪结果和增量子空间学习更新特征基使得它们易于发生模型漂移. 受到稀疏表示在人脸识别中应用的启示, 2009 年 Mei 和 Ling 提出了基

于稀疏表示的子空间跟踪<sup>[6]</sup>,即“L1跟踪”.L1跟踪以观测噪声符合拉普拉斯分布为假设,利用L1正则化最小二乘模型求解候选目标的稀疏表示系数,提高了子空间跟踪对目标遮挡的鲁棒性.但是L1跟踪存在两个问题,第一是L1跟踪要求解多个L1最小化问题,导致其速度较慢.针对该问题,一些研究者已经提出了一些方法<sup>[7,8]</sup>.第二是表示系数的稀疏性使得L1跟踪对模板中的离群数据(outliers)更加敏感,一旦模板中引入离群数据会导致跟踪失败.为此,文献[7]提出利用小模板系数检测遮挡并根据检测结果更新目标模板,但是由于小模板也能表示跟踪目标<sup>[8]</sup>,这时会导致检测失败.在L1跟踪的启发下,根据粒子在同一模板集上表示系数的低秩与稀疏结构,文献[9]提出一种基于稀疏与低秩学习的视觉跟踪方法,该方法虽然提高了子空间跟踪的跟踪精度,但是模型漂移问题仍然存在.

总之,传统子空间跟踪<sup>[1,5]</sup>对目标遮挡的鲁棒性较差,并且易发生模型漂移.虽然基于稀疏表示的子空间跟踪<sup>[6~9]</sup>提高了遮挡目标跟踪的鲁棒性,但是它对模板中的离群数据较敏感,更易发生模型漂移.针对子空间跟踪易受到模型漂移的影响而导致跟踪失败的不足,本文提出一种基于主分量寻踪的子空间跟踪方法.在表观模型方面,该方法利用多个模板张成的子空间和主分量寻踪(Principal Component Pursuit, PCP)求解候选目标的误差分量,在粒子滤波框架下,以候选目标的误差分量作为观测似然估计目标状态.与现有模型的不同在于:一方面,该模型利用了子空间产生式模型中观测噪声由高斯噪声和拉普拉斯噪声两部分组成这一先

验知识;另一方面,利用PCP求解候选目标的误差分量,对模板中的离群数据具有鲁棒性,即使目标模板中存在离群数据也能稳定跟踪目标.在模板更新方面,本文方法根据当前跟踪结果与目标模板的相似性,在线选择跟踪结果或其低秩分量更新目标模板,适应了目标表观变化并降低了模型漂移的发生.

## 2 主分量寻踪

为了克服了经典PCA易受离群数据干扰的不足,文献[10]提出鲁棒主分量分析(Robust Principal Component Analysis, RPCA).考虑到噪声对观测矩阵的影响,在RPCA的基础上,Zhou等人提出PCP<sup>[11]</sup>.PCP已在序列图像背景估计<sup>[11]</sup>和序列人脸图像配准<sup>[12]</sup>等计算机视觉问题中得到较好应用.PCP的目的是求解已知观测矩阵 $M \in \mathbf{R}^{m \times n}$ 的低秩矩阵 $L$ 与稀疏矩阵 $S$ ,其产生式模型如下所示:

$$M = L + S + Z \quad (1)$$

其中, $Z$ 是噪声项.为了求解式(1)中的低秩矩阵 $L$ 与稀疏矩阵 $S$ ,文献[11]证明了利用凸优化可以稳定求解式(1)中的低秩矩阵 $L$ 与稀疏矩阵 $S$ .

## 3 候选目标的分解与相似性度量

### 3.1 候选目标的分解

根据不同光照和视角下的目标表观近似处于一个低维子空间<sup>[1,5,6]</sup>这一假设,由文献[11]可知,利用目标模板和PCP可以将一个候选目标分解为低秩和误差分量两部分,如图1所示.




图1 候选目标的误差与低秩分量分解

假设目标模板  $T = [t_1, t_2, \dots, t_n] \in \mathbf{R}^{m \times n}$ , 其中  $t_i \in \mathbf{R}^m$  是目标模板图像按列存储形成的向量.任一跟踪结果或候选目标图像归一化到与目标模板同样大小,并按列存储形成列向量  $y \in \mathbf{R}^m$ .由文献[11~13]可知,若定义矩阵  $D = [y, T]$ ,则矩阵  $D$  可按式(2)分解为三项:

$$D = A + E + N \quad (2)$$

其中,  $A = [a_y, a_1, \dots, a_n]$  是低秩项,  $a_i$  和  $a_y$  分别是目标模板  $t_i$  和跟踪结果  $y$  的低秩分量.  $E = [e_y, e_1, \dots, e_n]$  是独立同分布的拉普拉斯误差项,  $e_i$  和  $e_y$  分别是目标模板  $t_i$  和跟踪结果  $y$  的误差分量.  $N = [n_y, n_1, \dots, n_n]$  是独立同分布的高斯噪声项,  $n_i$  和  $n_y$  分别是目标模板

$t_i$  和  $n_y$  的噪声分量.在视觉跟踪中,由于目标模板  $t_i$  具有较强的相关性,所以  $A$  具有低秩性.虽然较大的目标遮挡会导致误差分量  $e_y$  的每一项均非零,但是由于目标模板  $t_i$  具有较强的相关性使得  $e_i$  的非零项较少,所以误差矩阵  $E$  具有稀疏性,即矩阵  $E$  的非零项较少.噪声矩阵  $N$  对应于观测噪声,不可否认观测噪声是覆盖所有像元的,但是观测噪声的能量是有限的<sup>[13]</sup>.根据上述分析,由文献[11]可知,在已知矩阵  $D$  时,低秩矩阵  $A$  和误差矩阵  $E$  可以通过如下模型求解.

$$\min_{E, A} \text{rank}(A) \quad \text{s.t.} \quad \|D - A - E\|_F \leq \delta, \quad \|E\|_0 \leq k \quad (3)$$

其中,  $\text{rank}(\cdot)$  表示矩阵的秩,  $\|\cdot\|_F$  是矩阵的 Frobenius 范数,  $\delta$  是一个大于 0 的常数,  $\|\cdot\|_0$  是矩阵的  $l_0$  范数 (矩阵中非零项的个数),  $k$  是一个常量, 表示误差矩阵  $E$  中非零像素的最大数目. 优化问题式(3)易于写成如下拉格朗日形式:

$$\min_{A, E} \text{rank}(A) + \lambda \|E\|_0 \quad \text{s.t.} \quad \|D - A - E\|_F \leq \delta \quad (4)$$

其中,  $\lambda > 0$  是一个加权参数, 用于平衡矩阵  $A$  的秩和矩阵  $E$  的稀疏性. 文献[11]已经证明可以利用最小化矩阵核范数与  $l_1$  范数的组合稳定精确求解式(4), 其求解模型如下:

$$\min_{A, E} \|A\|_* + \lambda \|E\|_1 \quad \text{s.t.} \quad \|D - A - E\|_F \leq \delta \quad (5)$$

其中,  $\|\cdot\|_*$  和  $\|\cdot\|_1$  分别是矩阵的核范数和  $l_1$  范数, 参数  $\lambda$  取值为  $1/\sqrt{m}$  ( $m$  是矩阵  $D$  的行数). 本文利用增广拉格朗日乘子 (Augmented Lagrange Multiplier, ALM)<sup>[14]</sup> 算法求解式(5)的解.

### 3.2 相似性度量

由于好的候选目标与目标模板相似性强, 坏的候选目标与目标模板相似性弱, 所以好的候选目标其误差分量较小, 坏的候选目标其误差分量较大. 图 2 给出一个例子, 由图 2 可以看出: 与目标模板相似性强的候选目标其误差分量较小, 与目标模板相似性较弱的候选目标其误差分量较大, 即利用候选目标的误差分量可以度量候选目标与目标模板的相似性.



图2 候选目标及其误差分量

## 4 模板更新

为了适应目标表观变化需要更新目标模板, 为了限制模型漂移的发生需要使用静态模板, 因此本文把目标模板分成静态模板  $T^s = [t_1, \dots, t_{n/2}]$  和动态模板

$T^d = [t_{n/2+1}, \dots, t_n]$  两部分. 在目标跟踪过程中, 静态模板保持不变, 动态模板进行更新. 由于 PCP 能够精确求解存在离群数据的低维子空间, 所以自然地想方法是利用跟踪结果的低秩分量更新动态模板实现模板更新. 但是跟踪结果与目标模板之间会存在配准误差, 从而导致跟踪结果的低秩分量丢失部分目标信息. 考虑到视觉跟踪中目标表观变化具有平滑性, 当跟踪结果与动态模板相似时, 本文方法利用跟踪结果更新动态模板, 否则利用跟踪结果的低秩分量更新动态模板. 假设当前跟踪结果为  $y$ , 定义向量的相似性函数  $\text{sim}(\cdot, \cdot)$  为两个向量夹角的余弦, 则提出的模板更新方法如方法 1 所示, 其中  $n$  是目标模板的个数, 显然使目标模板包含所有可能的目标表观是  $n$  的最优选择, 但是视觉跟踪中目标表观的变化是不可预知的. 本文采用文献[6~8]中的方法, 取一个经验值.

#### 方法 1 模板更新

- 步骤 1 构建矩阵  $D = [y, T^d]$
- 步骤 2 利用式(5)求解跟踪结果  $y$  的低秩分量
- 步骤 3 计算相似性  $s_i = \text{sim}(y, t_i), i = n/2 + 1, \dots, n$
- 步骤 4 更新模板权重  $\alpha_i = \alpha_i * \text{sim}(y, t_i), i = n/2 + 1, \dots, n$
- 步骤 5 计算  $s_{\min} = \min(\{s_i\}_{i=n/2+1}^n)$
- 步骤 6 求解  $i_r = \arg \min_{n/2+1 \leq i \leq n} \alpha_i$
- 步骤 7 假如  $(s_{\min} < \tau)$  则  $t_r = y$  否则  $t_r = a$
- 步骤 8 令  $\alpha_i = \text{median}\{\alpha_{n/2+1}, \dots, \alpha_n\}$
- 步骤 9 权值归一化  $\alpha_i = \alpha_i / \sum_{i=n/2+1}^n \alpha_i$

与现有模板更新方法<sup>[1,6-9]</sup>不同, 一方面, 本文方法基于目标表观变化的平滑性, 利用当前跟踪结果更新动态模板, 适应了目标表观变化, 另一方面, 本文方法基于主分量寻踪的离群数据检测能力, 利用当前跟踪结果的低秩分量更新动态模板, 滤除了目标遮挡或者错误跟踪引起的离群数据, 降低了模型漂移的发生. 图 3 给出了本文模板更新与 APGL1 跟踪<sup>[7]</sup>模板更新的实验结果, 其中第一行为跟踪结果, 第二行为本文方法的模板更新结果, 第三行为 APGL1 跟踪的模板更新结



图3 本文模板更新与APGL1跟踪模板更新比较

果.由图 3 可以看出:APGLI 跟踪在模板更新时引入了背景信息,而本文方法在适应目标变化的同时保证了模板的正确性.

## 5 基于粒子滤波的目标跟踪

### 5.1 粒子滤波

粒子滤波是序贯贝叶斯滤波方法,包括预测和更新两个步骤.假设  $\mathbf{y}_{1:t-1} = \{\mathbf{y}_1, \dots, \mathbf{y}_{t-1}\}$  为 1 到  $t-1$  时刻的所有图像观测,则预测过程为:

$$p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) = \int p(\mathbf{x}_t | \mathbf{x}_{t-1})p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \quad (6)$$

其中,  $p(\mathbf{x}_t | \mathbf{x}_{t-1})$  是动态模型,  $\mathbf{x}_t$  表示  $t$  时刻的目标状态.在  $t$  时刻,当观测  $\mathbf{y}_t$  可用时,则执行如下更新过程:

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \frac{p(\mathbf{y}_t | \mathbf{x}_t)p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t | \mathbf{y}_{1:t-1})} \quad (7)$$

其中,  $p(\mathbf{y}_t | \mathbf{x}_t)$  为观测似然模型.在得到所有图像观测  $\mathbf{y}_{1:t} = \{\mathbf{y}_1, \dots, \mathbf{y}_t\}$  时,利用最大后验概率准则估计目标的最优状态  $\hat{\mathbf{x}}_t$ ,如下所示:

$$\hat{\mathbf{x}}_t = \arg \max_{\mathbf{x}_t} p(\mathbf{x}_t^i | \mathbf{y}_{1:t}) = \arg \max_{\mathbf{x}_t^i} p(\mathbf{y}_t^i | \mathbf{x}_t^i)p(\mathbf{x}_t^i | \mathbf{x}_{t-1}^i), \quad i = 1, 2, \dots, N \quad (8)$$

其中,  $\mathbf{x}_{t-1}^i$  和  $\mathbf{x}_t^i$  分别是第  $i$  个粒子在  $t-1$  和  $t$  时刻的状态,  $\mathbf{y}_t^i$  是  $t$  时刻第  $i$  个粒子的图像观测,  $N$  是粒子数.

### 5.2 动态模型

动态模型也称为运动模型,是目标状态在连续两帧图像之间的运动参数.本文利用仿射变换对目标的运动建模.令  $\mathbf{x}_t = (a_t^1, a_t^2, a_t^3, a_t^4, x_t^1, y_t^1)$ , 其中  $(a_t^1, a_t^2, a_t^3, a_t^4)$  和  $(x_t^1, y_t^1)$  分别是  $t$  时刻目标的变形参数和位置参数,则本文采用的动态模型如下:

$$p(\mathbf{x}_t | \mathbf{x}_{t-1}) = N(\mathbf{x}_t; \mathbf{x}_{t-1}, \Psi) \quad (9)$$

其中,  $\Psi$  是对角矩阵,其对角上的元素表示相应状态的方差.

### 5.3 观测似然模型

假设图像观测  $\mathbf{y}_t^i$  的误差分量和噪声分量分别是  $\mathbf{e}_t^i$  和  $\mathbf{n}_t^i$ .由产生式模型式(2)可知,  $\mathbf{y}_t^i$  的观测似然由  $\mathbf{e}_t^i$  和  $\mathbf{n}_t^i$  共同决定,但是由于噪声分量  $\mathbf{n}_t^i$  的能量有限,并且与误差分量  $\mathbf{e}_t^i$  相比其值可以忽略不计<sup>[11]</sup>,所以观测似然可由  $\mathbf{e}_t^i$  计算.由于误差分量  $\mathbf{e}_t^i$  符合拉普拉斯分布,所以任一图像观测  $\mathbf{y}_t^i$  的观测似然定义如下:

$$p(\mathbf{y}_t^i | \mathbf{x}_t^i) = \frac{1}{\Gamma} \exp(-\alpha \|\mathbf{e}_t^i\|_1) \quad (10)$$

其中,  $\alpha$  是高斯核尺度参数,  $\Gamma$  是归一化常量.

本文利用 PCP 求解候选目标的误差分量作为观测似然,对离群模板具有较强的鲁棒性,但是  $L_1$  跟踪利用稀疏表示求解候选目标的重建误差,易于受到离群

模板的干扰.图 4 给出了使用相同目标模板和参数  $\alpha = 0.01$ ,利用本文观测似然和  $L_1$  跟踪<sup>[6]</sup>观测似然得到的同一帧图像的似然图.由图 4 可以看出:在目标模板中有离群模板时,本文似然图中高似然值位于目标区域,但是在  $L_1$  跟踪似然图中的背景区域有高似然值,即本文方法对离群模板具有鲁棒性,而  $L_1$  跟踪易受离群模板的干扰.



图4 似然图比较(实线矩形为跟踪目标,虚线矩形为离群模板)

### 5.4 跟踪方法

以粒子滤波为框架,将动态模型、观测似然模型和模板更新方法相结合建立视觉跟踪方法,如方法 2 所示.

#### 方法 2 基于主分量寻踪的鲁棒跟踪方法

- 
- 步骤 1 初始化:初始化  $t = 1$  和粒子集合  $\{\mathbf{x}_1^i, 1/N\}_{i=1}^N$   
for  $t = 1$  to  $T$
- 步骤 2 状态预测:利用动态模型式(9)预测粒子状态  $\mathbf{x}_t^i$ ,并采样粒子  $\mathbf{x}_t^i$  的图像观测  $\mathbf{y}_t^i, i = 1, \dots, N$
- 步骤 3 权值更新:首先利用式(5)求解粒子  $\mathbf{y}_t^i$  的误差分量  $\mathbf{e}_t^i$ ,然后利用式(10)计算观测似然  $p(\mathbf{y}_t^i | \mathbf{x}_t^i)$ ,最后用  $w_t^i = w_{t-1}^i p(\mathbf{y}_t^i | \mathbf{x}_t^i)$  更新权值,  $i = 1, \dots, N$
- 步骤 4 权值归一化:  $w_t^i = w_t^i / \sum_{i=1}^N w_t^i, i = 1, \dots, N$
- 步骤 5 目标状态估计:  $\hat{\mathbf{x}}_t = \mathbf{x}_t^{\hat{i}}$ , 其中  $\hat{i} = \max_i(w_t^i)$
- 步骤 6 粒子重采样
- 步骤 7 利用方法 1 更新模板
- end
- 

## 6 实验结果与讨论

### 6.1 实验说明

以 Matlab R2011b 为开发工具实现了本文提出的跟踪方法(简称为 PCP 跟踪),并在 Pentium(R) Dual-Core 2.80GHz CPU, 2GB 内存的台式机上调试通过.用“three\_past\_shop”、“david”、“david3”和“jumping”测试序列<sup>[15]</sup>对 PCP 跟踪进行了实验验证,并与 IVT 跟踪<sup>[1]</sup>、APGLI 跟踪<sup>[7]</sup>和 LRST 跟踪<sup>[9]</sup>进行了比较.为了保证比较的合理性,实验中 4 种跟踪方法的粒子数均为 600. PCP 跟踪、APGLI 跟踪和 LRST 跟踪的模板数量是 10, 8 组实验的模板大小分别是  $18 \times 10$ 、 $22 \times 16$ 、 $18 \times 65$  和  $10 \times 15$ , 动

态模型参数是(0.06,0.01,0.01,0.06,5,5).

## 6.2 实验结果

图 5 给出了 4 种跟踪方法对 4 组测试序列的跟踪结果.“three\_past\_shop”序列的背景较复杂,由图 5(a)可以看出:对于“three\_past\_shop”序列,PCP 跟踪方法能稳定跟踪目标,而其它 3 种跟踪受到相似目标的干扰.“david”序列中目标存在较大的光照和姿态变化,从图 5

(b)可以看出:对于“david”序列,PCP 跟踪的精度和 IVT 跟踪相当,且优于其它 2 种跟踪方法.“david3”序列存在目标遮挡,从图 5(c)可以看出:对于“david3”序列,PCP 跟踪的精度优于其它 3 种跟踪方法.图 5(d)给出了对快速运动目标跟踪的结果,从图 5(d)可以看出:对于存在运动模糊的 jumping 序列,PCP 跟踪的结果最优.



图 5 测试序列的跟踪结果

由标准测试库<sup>[15]</sup>得到目标的真实状态,利用相对位置误差  $e = \epsilon/d$  定量评价跟踪方法的性能,其中,  $\epsilon$  是中心位置相对于真实位置的偏移量,  $d$  是目标矩形的对角长度.图 6 给出了 4 种跟踪方法对 4 组测试序列的跟踪位置误差曲线,其横坐标是图像序号,单位为帧,其纵坐标是相对位置误差,单位为像素.从图 6(a)可以看出:对于复杂背景下的“three\_past\_shop”序列,PCP 跟踪的精度优于其它 3 种跟踪方法.从图 6(b)可以看出:对于有较大光照和姿态变化的“david”序列,PCP 跟踪的精度与 IVT 跟踪相当,且优于其它 2 种跟踪方法.从图 6(c)可以看出:对于存在目标遮挡的“david3”序列,PCP

跟踪的精度优于其它 3 种跟踪方法.从图 6(d)可以看出:对于存在目标快速运动的“jumping”序列,PCP 跟踪的精度优于其它 3 种跟踪方法.

## 6.3 计算复杂度分析

本文 PCP 跟踪、IVT 跟踪、APGL1 跟踪和 LRST 跟踪均是粒子滤波框架下的子空间跟踪.假设  $U \in \mathbf{R}^{m \times n}$  是 IVT 跟踪的特征基,  $T \in \mathbf{R}^{m \times n}$  是 APGL1 跟踪、LRST 跟踪和本文 PCP 跟踪的目标模板,  $k$  是文献[7]中 APG 算法的迭代次数,  $N$  是这 4 个跟踪方法使用的粒子数.由文献[1,7,9]可知:IVT 跟踪、APGL1 跟踪和 LRST 跟踪的计算复杂度如表 1 所示.由文献[14]可知,求解式(5)的

计算复杂度是  $O(rmn)$ , 其中  $r \leq \sqrt{\min(m, n)}$  是矩阵  $A$  的秩. 由于  $n \ll m$ , 所以本文跟踪的计算复杂度为  $O(Nm)$ . 由上述分析可知: 这 4 个跟踪方法的时间复杂度级别相同, 都是变量多项式的复杂度. 表 1 中的第 3

列给出了在相同软硬件环境下,  $m = 32 \times 32$ ,  $n = 10$  和  $N = 600$  时, 进行一帧跟踪的平均时间. 由表 1 可以看出: 本文跟踪的速度比 IVT 跟踪慢, 但是比 APGL1 跟踪和 LRST 跟踪的速度快.

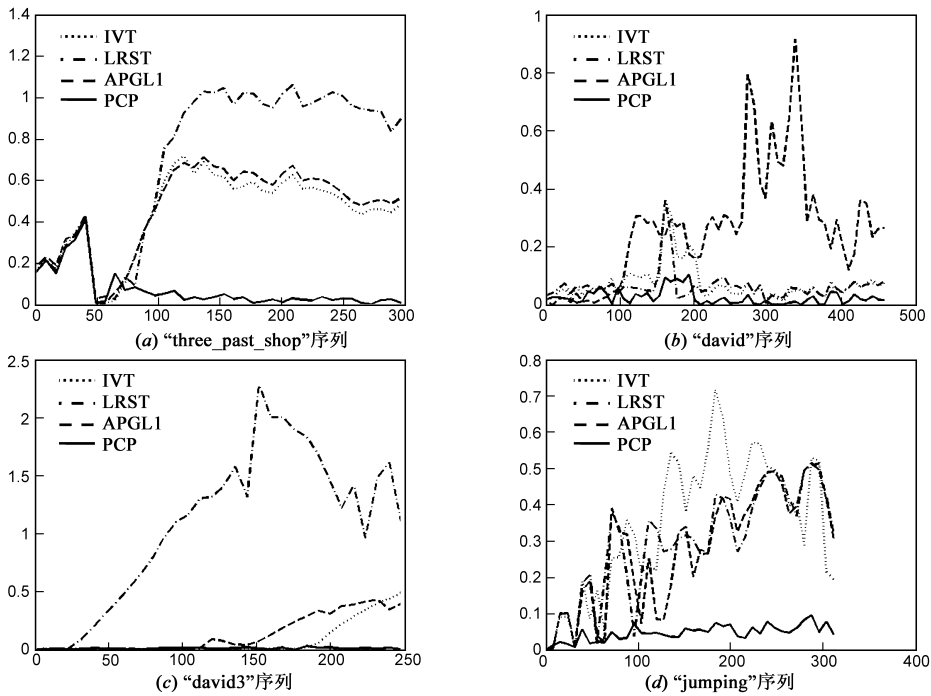


图6 相对位置误差曲线

表 1 计算复杂度与计算时间

跟踪方法	计算复杂度	计算时间(s)
IVT 跟踪 <sup>[1]</sup>	$O(Nmn)$	0.125
APGL1 跟踪 <sup>[7]</sup>	$O(Nkmn)$	2.282
LRST 跟踪 <sup>[9]</sup>	$O(Nm)$	2.124
本文 PCP 跟踪	$O(Nm)$	1.978

## 6.4 讨论

6.2 节验证了本文跟踪方法的鲁棒性, 但是与现有子空间跟踪方法<sup>[1,6]</sup>相同, 当目标存在快速的 out-plane 旋转时可能会发生跟踪失败. 图 7 给出了本文跟踪方法存在跟踪失败的两种情况. 图 7(a) 的跟踪目标为人头,



(a) 人头序列



(b) 人体序列

图7 两种跟踪失败情况

它存在 out-plane 旋转: 人头时而处于人脸正面、时而处于人脸侧面、时而又处于人脸背面. 图 7(b) 跟踪目标为人体, 它存在与图 7(a) 中类似的情况. 在这 2 组实验中, 均发现了跟踪失败, 这是进一步研究要解决的问题.

## 7 结论

针对子空间跟踪易于发生模型漂移的不足, 本文提出一种基于主分量寻踪的鲁棒视觉跟踪方法. 一方面, 该方法利用目标模板和主分量寻踪求解候选目标的误差分量, 利用候选目标的误差分量建立观测似然跟踪目标, 提高了对目标模板中离群数据的鲁棒性. 另一方面, 为了适应目标变化并克服模型漂移问题, 该方法将目标模板分成静态模板和动态模板两部分, 当跟踪结果与动态模板相似时利用跟踪结果更新动态模板, 否则利用当前跟踪结果的低秩分量更新动态模板. 在上述两个方面的基础上, 以粒子滤波为框架实现了基于主分量寻踪的鲁棒视觉跟踪方法. 利用具有挑战性的图像序列对提出的跟踪方法进行了实验验证并与现有跟踪方法进行了比较, 实验结果表明: 与现有跟踪方法相比, 本文方法具有较强的鲁棒性.

## 参考文献

- [1] Ross D, Lim J, Lin R S, et al. Incremental learning for robust visual tracking[J]. International Journal of Computer Vision, 2008, 77(1-3): 125-141.
- [2] Babenko B, Yang M H, Belongie S. Robust object tracking with online multiple instance learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1619-1632.
- [3] Kwon J, Lee K M. Visual tracking decomposition[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Los Alamitos: IEEE Computer Society Press, 2010. 1269-1276.
- [4] Michael J Black, Allan D Jepson. Eigentracking: Robust matching and tracking of articulated objects using a view-based representation[J]. International Journal of Computer Vision, 1998, 26(1): 63-84.
- [5] 温静, 李洁, 高新波. 张量子空间学习的自适应目标跟踪[J]. 电子学报, 2009, 37(7): 1618-1623.  
Wen Jing, Li Jie, Gao Xin-bo. Adaptive object tracking with incremental tensor subspace learning[J]. Acta Electronica Sinica, 2009, 37(7): 1618-1623. (in Chinese)
- [6] Xue Mei, Haibin Ling. Robust visual tracking using  $l_1$  minimization[A]. Proceedings of IEEE Conference on Computer Vision[C]. Kyoto: IEEE Computer Society Press, 2009. 1436-1443.
- [7] Mei X, Ling H B, Wu Y, et al. Minimum error bounded efficient  $L_1$  tracker with occlusion detection[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Colorado: IEEE Computer Society Press, 2011. 1257-1264.
- [8] Chenglong Bao, Yi Wu, Haibin Ling, et al. Real time robust  $L_1$  tracker using accelerated proximal gradient approach[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Rhode Island: IEEE Computer Society Press, 2012. 1830-1837.
- [9] Tianzhu Zhang, Bernard Ghanem, Si Liu, et al. Low-rank sparse learning for robust visual tracking[A]. Proceedings of Conference on European Conference on Computer Vision[C]. Florence: Springer, 2012. 470-484.
- [10] John Wright, Yigang Peng, Yi Ma. Robust principal component analysis: exact recovery of corrupted low-rank matrices by convex optimization[A]. Advance in Neural Information Processing Systems[C]. Vancouver, B C: MIT Press, 2009. 2080-2088.
- [11] Zihan Zhou, Xiaodong Li, John Wright, et al. Stable principal component pursuit[A]. Proceedings of International Symposium on Information Theory[C]. Austin: IEEE Press, 2010. 1518-1522.
- [12] Yigang Peng, Arvind Ganesh, John Wright, et al. RASL: Robust alignment by sparse and low-rank decomposition for linearly correlated images[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. San Francisco: IEEE Computer Society Press, 2010. 763-770.
- [13] 胡谋法, 董文娟, 王书宏, 等. 奇异值分解带通滤波背景抑制和去噪[J]. 电子学报, 2008, 36(1): 111-116.  
Hu Mou-fa, Dong Wen-juan, Wang Shu-hong, et al. Singular-value decomposition band-pass-filter for image background suppression and denosing[J]. Acta Electronica Sinica, 2008, 36(1): 111-116. (in Chinese)
- [14] Zhouchen Lin, Minming Chen, Leqin Wu, et al. The Augmented Lagrange Multiplier Method for Exact Recovery of Corrupted Low-Rank Matrices[R/OL]. <http://yima.csl.illinois.edu/psfile/Lin09-MP.pdf>, arXiv: 1009.5055v2, 2009.
- [15] Yi Wu, Jongwoo Lim, Ming-Hsuan Yang. Online object tracking: a benchmark[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Portland: IEEE Computer Society Press, 2013. 2411-2418.

## 作者简介



袁广林 男, 1973年08月出生于河南周口. 博士, 讲师, 主要研究方向为图像处理、计算机视觉、机器学习及其应用等.

E-mail: yuanguanglin1008@sina.com



薛模根 男, 1964年10月出生于安徽合肥. 博士, 教授, 合肥工业大学博士生导师, 主要研究方向为图像处理、计算机视觉、光电防御等.

E-mail: xuemogen@126.com