

## 采用多重约束的无人机导航 KLT 视觉跟踪算法

宋琳,程咏梅,刘楠,刘夏雷

(西北工业大学自动化学院,陕西西安 710072)

**摘要:** 特征点跟踪是实现无人机视觉里程计导航的重要技术。针对无人机视频图像帧间运动较大造成帧间的特征点跟踪误差大的问题,提出一种基于时间可逆性约束和双向偏移量约束相结合的多重约束 KLT 特征点跟踪策略,并在金字塔表示下分层求解跟踪点的偏移量。基于时间可逆性约束,建立新的融合前向跟踪和后向跟踪的目标函数,解算前向跟踪偏移量和后向跟踪偏移量,并构造新的帧间偏移量-双向偏移量,在金字塔分层表示结构下实现偏移量的最优估计。实验结果表明,该方法能够有效地实现帧间特征点的精确跟踪,与同类跟踪算法相比有较好的效果。

**关键词:** 特征点跟踪; 时间可逆性; 双向偏移量

**中图分类号:** TP391.4 **文献标志码:** A **文章编号:** 1007-2276(2013)10-2828-08

## Algorithm of vision tracking for UAV navigation based on multi-constraint KLT

Song Lin, Cheng Yongmei, Liu Nan, Liu Xialei

(School of Automation, Northwestern Polytechnical University, Xi'an 710072, China)

**Abstract:** Feature point tracking is an important technology to implement the visual odometry for navigation. Aiming at the problem of feature tracking with big errors caused by large motion of the video fixed on UAV, a multi-constraint KLT tracking strategy based on time-reversibility and bi-directional displacement constraint was proposed and the pyramid model was used for the hierarchical displacement computation of the tracking points. The new objective function was set up according to the fusion of forward and backward tracking. A new bi-directional displacement was constructed based on the displacements of forward and backward tracking, and the optimal estimation of the displacements was implemented in the structure of pyramid model. The experiment results demonstrate that the proposed algorithm improves the performance of precise tracking effectively and outperforms the similar tracker.

**Key words:** feature point tracking; time-reversibility; bi-directional displacement

收稿日期:2013-02-17; 修订日期:2013-03-10

基金项目:西安市科技计划项目(CXY1350(2));航空科学基金(20100853010)

作者简介:宋琳(1983-),男,博士生,主要从事信息融合、视觉导航、模式识别方面的研究。Email:linsong0818@163.com

导师简介:程咏梅(1960-),女,教授,博士,主要从事信息融合、模式识别方面的研究。Email:chengym@nwpu.edu.cn

## 0 引言

视觉里程计是利用序列图像中对应点的位置变化计算在对应时间内的位移,从而实现运动物体的航迹推算和相对运动的估计,在机器人及无人驾驶汽车中得到了广泛的应用。如何得到序列帧图像中对应的点对,即特征点匹配问题,是实现视觉里程计的关键。特征点匹配的本质是寻求两幅图像特征点集的空间映射关系<sup>[1]</sup>。匹配策略主要包括两类:基于穷尽搜索的特征点匹配和基于最优估计的特征点匹配。基于穷尽搜索的特征点匹配本质是在已知的两个特征点集之间分别进行搜索匹配找到各个特征点所对应的最优匹配点。如 Harris 角点匹配<sup>[2]</sup>, Sift 特征匹配<sup>[3]</sup>等。这类方法依赖于所选取特征的鲁棒性,且在匹配的过程中,以遍历方式对特征点集进行比较匹配,没有充分利用帧间的先验信息,严重影响了计算速度。基于最优估计的特征点跟踪则是通过一幅图像上的已知特征点集寻找在另一幅图像上这些特征点的最优估计位置,其典型代表为光流法。KLT 是一种典型的基于稀疏光流的特征点跟踪方法<sup>[4-5]</sup>,在计算时提取相对稀疏、具有明显差异的特征点,通过优化估计这些特征点在图像中的位置来完成特征点的匹配。

KLT 算法将图像匹配问题从遍历的搜索匹配策略变为一个求解偏移量的过程,在视觉里程计的研究中得到认可。Gianpaolo Conte 等在无人机视觉导航中引入 KLT 跟踪算法完成帧间相同特征点的匹配,实现了视觉里程计的计算<sup>[6]</sup>。然而 KLT 算法以帧间平移模型为基础,对于帧间运动较大情况下光流估计误差较大,无法得到正确匹配的特征点,从而增大相对运动估计的累计误差。S. Birchfield 等基于金字塔分层结构实现了 KLT 算法<sup>[7]</sup>,对较大运动的跟踪效果和运算速度都有一定提高,但该方法中由于 KLT 所定义约束条件对目标从  $t$  时刻到  $(t+1)$  时刻的运动进行估计,即所谓的前向跟踪 (Forward Tracking),因此对所跟踪的特征点只能保证局部最优,对于较大的帧间运动无法保证结果的准确性。目标运动还有一个基本属性-时间可逆性约束 (TRC),即利用同一约束条件仍旧可以从  $(t+1)$  时刻图像到  $t$  时刻图像对同一目标点进行跟踪,即所谓后向跟踪 (Backward Tracking)。Hao Wu 等引入时间可逆性约束<sup>[8]</sup>,结合前向跟踪和后向跟踪重新定义了最小化

相似性准则直接实现预测跟踪,一定程度加强了对跟踪准确性的约束,但对于较大运动的跟踪效果却不理想。文中基于时间可逆性约束思想,在求解前向跟踪偏移量的同时利用后向跟踪构造了一种新的偏移量-双向偏移量,在图像的金字塔表示模型下对帧间变化较大的运动进行有效估计。仿真实验证明该方法在帧间运动较大的情况下具有很好的特征跟踪效果,能够有效地减小累积误差。

## 1 KLT 特征点跟踪

### 1.1 基本原理

设  $t$  时刻图像帧表示为  $I(x, y, t)$ ,  $t+1$  时刻对应的图像帧表示为  $I(x, y, t+1)$ , 它们的位置满足亮度恒定方程(1)。

$$I(x, y, t) = I(x+v_x, y+v_y, t+1) \quad (1)$$

在  $I(x, y, t+1)$  中的每个像素点,都可以由  $I(x, y, t)$  中特征窗口  $W$  的像素点平移  $v=(v_x, v_y)^T$  得到。将  $I(x+v_x, y+v_y, t+1)$  利用 Taylor 公式展开,去掉高次项,只保留前两项,得:

$$I(x+v_x, y+v_y, t+1) \approx I(x, y, t) + I_x(x, y, t) \cdot v_x + I_y(x, y, t) \cdot v_y + I_t(x, y, t) \quad (2)$$

这里  $I_x(x, y, t)$  和  $I_y(x, y, t)$  分别为图像  $I$  在  $X$  方向和  $Y$  方向的梯度  $\nabla I = [I_x(x, y, t), I_y(x, y, t)]$ , 而时间梯度  $I_t(x, y, t)$  (简称为  $I_t$ ) 如公式(3)所示。

$$I_t = I(x, y, t+1) - I(x, y, t) \quad (3)$$

因此可得到梯度约束方程:

$$\nabla I \cdot v + I_t = 0 \quad (4)$$

KLT 算法在以最小化窗口  $W$  下的灰度误差平方和 (SSD) 为目标函数的约束下求出。

$$v = \underset{v}{\operatorname{argmin}} \iint_w (I(x, y, t) - J(x+v_x, y+v_y, t+1))^2 dx \quad (5)$$

对于相邻两帧之间特定窗口  $W=(2w_x+1, 2w_y+1)$  (如图 1 所示) 上灰度误差平方和  $\varepsilon$ , 将公式(5)中的




图 1 特定窗口  $W$  下某个特征点  $(u_x, u_y)$

Fig.1 Feature point  $(u_x, u_y)$  with certain window  $W$

目标函数表示为离散形式,如公式(6)所示。

$$\varepsilon(\mathbf{v}) = \varepsilon(v_x, v_y) = \sum_{x=u_x-w_x}^{u_x+w_x} \sum_{y=u_y-w_y}^{u_y+w_y} (I(x, y, t) - I(x+v_x, y+v_y, t+1))^2 \quad (6)$$

这里为方便公式推导,令  $\sum_{x=u_x-w_x}^{u_x+w_x} \sum_{y=u_y-w_y}^{u_y+w_y} \triangleq \sum_W$ 。当

$\frac{\partial \varepsilon(\mathbf{v})}{\partial \mathbf{v}} = 0$  时,  $\varepsilon$  取得极值,将公式(5)代入公式(6),对公式(6)两边求导

$$\frac{1}{2} \left[ \frac{\partial \varepsilon(\mathbf{v})}{\partial \mathbf{v}} \right]^T \approx \sum_W (\nabla I \cdot \mathbf{v} + I_t) \cdot \nabla I^T \quad (7)$$

因此可得  $\bar{\mathbf{v}}$  的最优表达  $\bar{\mathbf{v}}_{opt}$ 。

$$\bar{\mathbf{v}}_{opt} = \left\{ \sum_W \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \right\}^{-1} \cdot \left\{ \sum_W \begin{bmatrix} -I_t \cdot I_x \\ -I_t \cdot I_y \end{bmatrix} \right\} \quad (8)$$

由公式(8)可以看出,影响最后的最优估计结果的因素主要有两个:(1)梯度矩阵;(2)特定窗口。对于前者, Jianbo Shi 和 Tomasi 等人通过判断特征矩阵的特征值来选择有效特征点<sup>[9]</sup>;对于后者,通过引入金字塔模型可对大尺度运动跟踪进行最优估计<sup>[7]</sup>。

### 1.2 精确跟踪的适用范围分析

KLT 方法基于最优估计理论进行特征点运动的预测跟踪。但是“运动”是有一个定义范围,当帧间重合区域较少或几乎没有时,则无法在局部范围内进行特征搜索。以平移运动为例,在特征点确定的情况下,跟踪最优估计范围与特征窗口  $W$  的大小有关,由于采用金字塔分层结构,在当前计算完偏移量  $(v_x, v_y)$  需要返回上一层继续计算,因此上一层的偏移初始量为  $(2v_x, 2v_y)$ ,如图 2 所示。因此最优估计范围还与金字塔的层数 Level 相关。

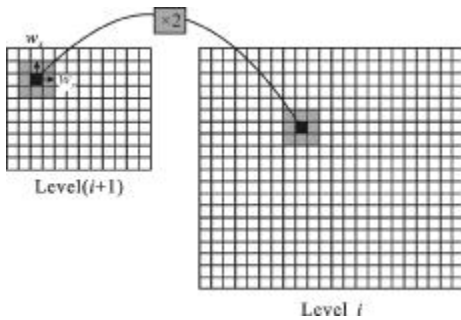


图 2 金字塔模型下的误差的分层估计

Fig.2 Hierarchical estimation of error using pyramidal model

因此,在  $X$  轴方向上,最终特征点偏移量的最大

估计范围是  $\sum_{i=0,1,\dots,n} 2^i \times w_x$ , 其中  $n$  为最大分解层数,

同理  $Y$  轴方向上,特征点偏移量的最大估计范围是  $\sum_{i=0,1,\dots,n} 2^i \times w_y$ 。当帧间运动超出这个范围时, KLT 算法即失效。文中针对帧间图像在可估计范围内的“较大”运动下特征点的精确跟踪问题展开研究。

## 2 基于多重约束的KLT跟踪

为了能够在跟踪的过程中准确跟踪特征点,去除干扰点,文中提出基于多重约束的 KLT 跟踪算法(MC-KLT),采用时间可逆性约束思想,构造新的双向偏移量约束,结合金字塔模型,对特征点进行最优估计。

### 2.1 时间可逆性约束

时间可逆性是目标运动的一个基本属性,它的基本思想是目标从  $t$  时刻到  $t+1$  时刻的运动约束方程适用于从  $t+1$  时刻到  $t$  时刻的运动估计,即在时间域上是可逆的。以  $\mathbf{v}^f$  和  $\mathbf{v}^b$  分别表示为前向跟踪(从  $t$  时刻到  $t+1$  时刻)和后向跟踪( $t+1$  时刻到  $t$  时刻)的偏移量,如图 3 所示。




图 3 前向跟踪与后向跟踪

Fig.3 Forward tracking and backward tracking

基于时间可逆性约束的 KLT 算法 (TRC-KLT) 融合前向跟踪和后向跟踪的目标函数,构造新的目标函数,从而在新的约束下求得更加鲁棒的前向跟踪特征点的偏移量  $\mathbf{v}^f$ 。

$$\begin{aligned} (\mathbf{v}^f, \mathbf{v}^b) = \operatorname{argmin}_{\mathbf{v}^f, \mathbf{v}^b} & \iint w [I(\mathbf{X}) - J(\mathbf{X} + \mathbf{v}^f)]^2 d\mathbf{X} + \\ & \iint w [J(\mathbf{X} + \mathbf{v}^f) - I(\mathbf{X} + \mathbf{v}^f + \mathbf{v}^b)]^2 d\mathbf{X} + \\ & \lambda (\mathbf{v}^f + \mathbf{v}^b)^T (\mathbf{v}^f + \mathbf{v}^b) \end{aligned} \quad (9)$$

利用 Taylor 级数展开公式,  $J(\mathbf{X} + \mathbf{v}^f)$  和  $I(\mathbf{X} + \mathbf{v}^f + \mathbf{v}^b)$  分别可得:

$$\begin{aligned} I(\mathbf{X} + \mathbf{v}^f + \mathbf{v}^b) & \approx I(\mathbf{X}) + \nabla I \cdot (\mathbf{v}^f + \mathbf{v}^b) \\ J(\mathbf{X} + \mathbf{v}^f) & \approx J(\mathbf{X}) + \nabla J \cdot \mathbf{v}^f \end{aligned} \quad (10)$$

对公式(9)的目标函数分别求关于  $\mathbf{v}^f$  和  $\mathbf{v}^b$  的偏

导并置零以期求得极值。

$$\begin{aligned}
 0 &= \sum_W [(I-J)(\nabla I - 2 \cdot \nabla J)^T + (\nabla I^T \nabla I - \nabla J^T \nabla J) v^b] + \\
 &\sum_W [(\nabla I^T \nabla I - \nabla J^T \nabla J - \nabla I^T \nabla J + 2 \nabla J^T \nabla J) v^f] + \lambda(v^f + v^b) \\
 0 &= \sum_W [(I-J) \nabla I^T + (\nabla I^T \nabla I - \nabla I^T \nabla J) v^f] + \\
 &\sum_W (\nabla I^T \nabla I) v^b + \lambda(v^f + v^b) \tag{11}
 \end{aligned}$$

为简化推导,定义  $A$ 、 $B$ 、 $C$ 、 $D$ 、 $R$ 、 $S$ 、 $V$ 、 $W$  分别为梯度的函数,如公式(12)所示。

$$\begin{aligned}
 A &= \sum_W (\nabla I)^T \nabla I; B = \sum_W (\nabla I)^T \nabla J \\
 C &= \sum_W (\nabla J)^T \nabla J; D = \sum_W (\nabla J)^T \nabla I \\
 R &= \sum_W I(\nabla I)^T; S = \sum_W J(\nabla I)^T \\
 V &= \sum_W I(\nabla J)^T; W = \sum_W J(\nabla J)^T \tag{12}
 \end{aligned}$$

则前向跟踪平移量  $v^f$  为:

$$v^f = (2(A + \lambda I)D^{-1} - B)^{-1} \cdot (2(A + \lambda I)D^{-1}(V - W) + (S - R)) \tag{13}$$

### 2.2 双向偏移量约束

TRC-KLT 算法有效地将前向跟踪和后向跟踪约束结合起来对平移向量进行估计,但没有有效地利用后向平移向量  $v^b$ 。后向跟踪的引入为反馈验证前向跟踪结果的准确性提供了一种实现途径<sup>[10]</sup>,而且基于前向偏移量和后向偏移量构造综合偏移量,能够有效减小偏移量的估计误差。由公式(11)可以求出后向平移向量  $v^b$ 。

$$\begin{aligned}
 v^b &= ((A - B + \lambda I)(2C - D)^{-1}D + A + \lambda I)^{-1} \cdot \\
 &(2(A - B + \lambda I)(2C - D)^{-1}(W - V) + (S - R)) \tag{14}
 \end{aligned}$$

如果  $t$  时刻特征点集  $Points(t)$  前向跟踪结果精确,得到特征点集  $Points(t+1)$ ,根据时间可逆性约束,以  $Points(t+1)$  为初始点进行后向跟踪,跟踪结果  $Points(t_b)$  应该与  $Points(t)$  相同或对应点间的距离很小,即  $\|v^f + v^b\|_2 \sim 0$ ; 当  $Points(t_b)$  与  $Points(t)$  对应点相差较大时,即  $\|v^f + v^b\|_2 \geq Theshold$ ,可以认为此刻的跟踪失败为校正误差,可取前向偏移量和后向偏移量的均值作为新的偏移量-双向偏移量,构造思想如图4所示。




图 4 双向偏移量的构造原理

Fig.4 Principle of bi-directional displacement

新的偏移量需要与原始偏移量的大小保持一致,因此采用加权的方式对  $v^b$  和  $v^f$  进行组合,由于  $v^f$  与理想状态下  $v^b_{expected}$  方向相反,加权时  $v^b$  的系数为负,因此构造新的偏移量  $v^{new}$  如下:

$$v^{new} = \alpha \times v^f + (1 - \alpha) \times (-v^b) \tag{15}$$

### 2.3 金字塔模型

为适应较大尺度运动的需求,包括平移、旋转等,引入金字塔模型对图像进行分层处理。图像的金字塔表示是一种多分辨率的图像结构,它通过对原始图像逐步采样而得到一个不同尺度的图像序列,高分辨率图像上的物体的较大运动,对应到低分辨率图上就变为相对较小的运动,有利于光流计算。设第 0 层为原始图像,则从第  $L-1$  层到第  $L$  层的采样窗口为  $5 \times 5$ ,采样公式如公式(16)所示,采样权重  $\alpha$  如图 5 所示。

$$I^L(i, j) = \frac{1}{256} \times \sum_{n=1:5} \sum_{m=1:5} \alpha(m, n) I^{L-1}(2i-3+m, 2j-3+n) \tag{16}$$




图 5 采样权重  $\alpha$

Fig.5 Sampling weight  $\alpha$

光流计算自顶层向下依次进行。在第  $L$  层计算平移向量后,经尺度变换作为下一层  $L-1$  层更高精度搜索计算的初始值。

## 2.4 算法描述

基于多重约束的 KLT 跟踪算法的具体流程如下:

- (1) 利用公式(16)生成相邻序列帧图像  $I(t)$  和  $I(t+1)$  的金字塔表示  $\{I_t^L\}_{L=0,1,2,\dots,n}$  和  $\{I_{t+1}^L\}_{L=0,1,2,\dots,n}$ ; 对于  $I_t^0$ , 检测特征点  $\{P_K^0\}_{K=1,2,\dots,m}$ , 其中  $m$  为特征点个数;
- (2) 自顶层向下依次进行计算, 如表 1 所示。

表 1 基于金字塔模型的 MC-KLT 光流算法

Tab.1 Algorithm of MC-KLT based on pyramid model

Algorithm discription
Algorithm discription: For $L=n:-1:0$ Detect feature points of $I_t^L$ , as $\{P_K^L\}_{K=1,2,\dots,m}=\{P_K^0/2^L\}_{K=1,2,\dots,m}$ ; For $K=1:1:m$ Initialize displacement $E_K^L=[0,0]$ ; Solve Eq.(13) and (14) to obtain $v_K^L$ and $(v_K^b)^L$ ; Compute $(v^{new})$ using Eq.(15); If $\ v^L+v^b\ _2 \geq \text{Theshhold1}$ Break; else If $v^L \geq \text{Theshhold2}$ $E_K^L=E_K^L+(v^{new})^L$ ; else Break; End End End End Displacement in $L^{\text{th}}$ level is $\{E_K^L\}_{K=1,2,\dots,m}$ ; If $L=0$ The final displacement is $\{E_K^L\}_{K=1,2,\dots,m}$ ; else Initial searching value in $(L-1)^{\text{th}}$ level is $\{2 \times E_K^L\}_{K=1,2,\dots,m}$ ; End End

(3) 根据  $I_t^0$  中检测特征点  $\{P_K^0\}_{K=1,2,\dots,m}$  及所估计得到平移向量  $\{E_K^0\}_{K=1,2,\dots,m}$  得到  $I_{t+1}^0$  中所跟踪到的对应特征点, 如公式(17)所示。

$$\{P_{K+1}^0\}_{K=1,2,\dots,m}=\{P_K^0\}_{K=1,2,\dots,m}+\{E_K^0\}_{K=1,2,\dots,m} \quad (17)$$

## 3 仿真实验及分析

文中首先采用仿真航拍序列图像验证算法进行

鲁棒性测试, 最后利用真实航拍序列图像进行跟踪精度的对比测试。作为对比, 基于 Matlab 平台分别利用原始 KLT 算法<sup>[7]</sup>(Ini-KLT)、参考文献[8]所提出的基于时间可逆性约束的 KLT 算法(TRC-KLT)和文中所提出的 MC-KLT 算法对测试集合进行特征点跟踪计算。

### 3.1 基于仿真航拍序列图像的鲁棒性测试

文中所研究的特征点跟踪方法不同于目标跟踪, 后者是通过利用特征点跟踪达到目标识别定位的目的, 而前者着重于建立序列图像的帧间变换关系, 从而达到对飞机的帧间相对运动估计的目的。因此一些影响目标跟踪的因素并不是研究的重点, 例如目标跟踪中的遮挡问题, 在帧间特征点跟踪时, 如果第  $i$  帧的特征点在第  $i+1$  帧图像中被遮挡, 根据文中所提出的双向跟踪约束, 该点会判定为被舍弃, 如表 1 所示算法; 如果第  $i+1$  帧图像中被遮挡的特征点较多时, 则无法对第  $i$  和  $i+1$  帧的相对运动进行估计, 则舍弃第  $i$  帧, 直接对第  $i+1$  帧图像进行特征点的提取并进行特征点在第  $i+2$  帧图像中的跟踪, 因此不会出现目标跟踪中目标丢失的情况。当帧间出现光照影响时亦如此处理。

对于文中所研究的特征点跟踪方法, 帧间“较大”的运动是主要的影响因素, 包括较大的平移和旋转。

#### (1) 较大平移测试

构造仅存在平移变化的图像对进行测试。根据 1.2 节的讨论, 可根据平移的大致范围, 确定特征跟踪窗口  $(w_x, w_y)$  和金字塔分解层数 Level。大量仿真实验表明: 三种算法对平移运动下的特征点跟踪效果都较好, 这是由于 KLT 算法是基于帧间平移运动模型而进行求解偏移量, 因此, 对于平移运动的鲁棒性较好。这里给出一组测试结果, 构造帧间平移大小为 28 个像素的图像对, 如图 6 所示, 图(a)No.1 表示初




图 6 平移运动下的图像特征点跟踪

Fig.6 Feature tracking with translational motion

始图像,图(b)No.28 表示相对于初始图像平移 28 个像素的图像,因此,确定跟踪窗口为(4, 4),分解层数为 Level=2,图(c)为图像特征点跟踪结果,带箭头的线段长度表示跟踪点的偏移量大小,箭头方向为跟踪点的运动方向。三种跟踪算法的跟踪结果对比如表 2 所示。

表 2 平移运动下的跟踪精度对比(单位:pixel)

Tab.2 Comparison of sum of displacement computation error (unit:pixel)

Method	X direction	Y direction
Truth	0	28
Ini-KLT	0.002	27.998
TRC-KLT	0.003	28.012
MC-KLT	0.002	28.006

由表 2 可以看出,对于平移运动,只要在 1.2 节所述的合理范围内,三种算法都可正确求解,且精度相差不多,都已达到亚像素级别。

(2) 较大旋转测试

为验证在较大旋转运动下的鲁棒性,文中构造了仅存在旋转差异的图像对进行测试,并通过手动选取控制点,进行匹配变换,并计算帧间图像相对运动变化作为基准。图 7 给出旋转角度差异在 15°时的特征点跟踪结果。




图 7 旋转运动下的图像特征点跟踪  
Fig.7 Feature tracking with rotational motion

从图 7(b)和(c)中可以看出红色所表示文中跟踪算法的跟踪特征点与其他两种算法相比较,与真实结果更为接近。由于在旋转运动下,每个特征点的运动位移大小及方向不同,因此统计所估计特征点与真值间的偏差均值,结果如图 8 所示。可见文中算法在旋转运动下的鲁棒性很好,且精度要高于 Ini-KLT 和 TRC-KLT 算法。




图 8 帧间旋转运动下的跟踪误差统计结果

Fig.8 Statistical error of feature tracking with rotational motion

3.2 基于真实航拍图像的跟踪精度的对比

利用真实航拍序列图像(<http://www.diegmunid.it/fusiello/demo/stab/file4.mpg>)进行测试。该航拍视频共有 94 帧图像,同时存在平移、旋转和一定的尺度变化,例如图 9(a)、(b)所示的第 1 帧和第 94 帧图像。通过手动选取控制点,进行匹配变换,并计算帧间图像相对运动变化,如图 9(c)和(d)所示。

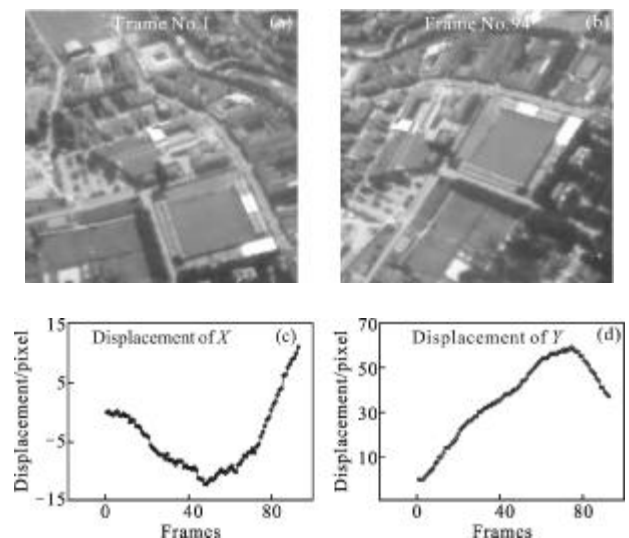


图 9 序列图像示例

Fig.9 Examples of image sequences

(1) 两帧图像间的跟踪结果

由于每两帧之间的运动较小,无法体现算法的优越性,因此从原始图像序列中按照 Baseline 帧的间隔进行两帧间的跟踪,对于该组图像序列,通过实验验证当  $Baseline > 20$  时,无论是哪种跟踪算法都无法得到正确结果。因此为验证算法在大尺度运动下的鲁棒性,取  $Baseline = 20$ , 设  $\{(i, i + Baseline) | i = 1, 2, \dots, 94 - Baseline\}$  为特征点跟踪测试的集合。考虑到公式(15)中待定参数  $\alpha$  的影响,通过大量样本实验,取  $\alpha = 0.2$ 。其中从第 1~20 帧的跟踪结果如图 10 所示。




图 10 从第 1 帧到第 20 帧的跟踪结果  
Fig.10 Tracking results from 1st to 20th frame

图 10(a)中给出所跟踪特征点;图(b)为分别利用三种跟踪算法对第 1 帧图像中的待跟踪特征点进行跟踪的结果,由图(c)可以看出文中跟踪算法的跟踪特征点与其他两种算法相比较,与真实结果更为接近。由于在无人机视觉导航的过程,通常只关心图像中心点的位置差异,因此统计图像中心点的偏移量误差如图 11 所示。

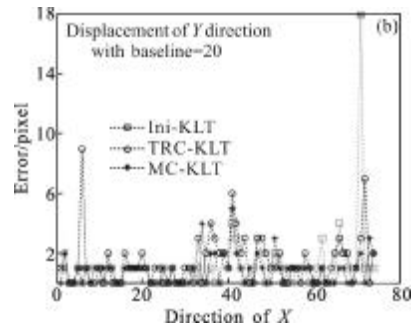
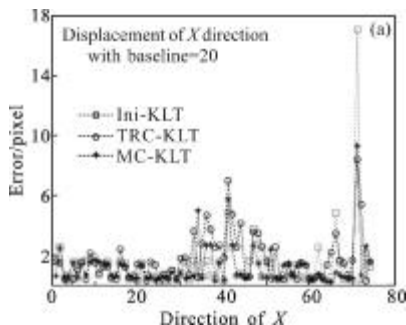


图 11 图像中心偏移量  
Fig.11 Point displacements of image center

可以看出,MC-KLT 算法结果的偏移误差总体趋势要好于前两种算法,对三种算法结果的误差绝对值做平均统计,如表 3 所示。表 3 中,文中所提出算法在两帧间的跟踪精度具有明显的优势。同时,在运算速度上,虽然对 KLT 算法增加了约束,但运算时间与前两种方法相当。

表 3 偏移量计算的误差和时间对比

Tab.3 Comparison of displacement error and computation time

Method	Mean of Error/pixel		Time/s
	X direction	Y direction	
Ini-KLT	1.319 7	1.108 1	1.085
TRC-KLT	1.676 7	1.378 4	1.101
MC-KLT	1.190 7	0.837 8	1.123

(2) 多帧的跟踪结果

由于序列图像的偏移量是一个累计的过程,因此多帧连续跟踪的累计偏移更能说明问题。分别取构造新的图像序列,图 12(a)~(d)给出从序列帧集合的跟踪结果,图(e)为分别利用匹配点对将图像序列进行拼接的结果。

为分析算法的跟踪精度,分别将 Ini-KLT、TRC-KLT 和 MC-KLT 跟踪结果的偏移量进行累计计算,结果如图 13 所示。

从图 13 中可以看出,文中算法在偏移量累计误差与前两种方法相比有显著改善。

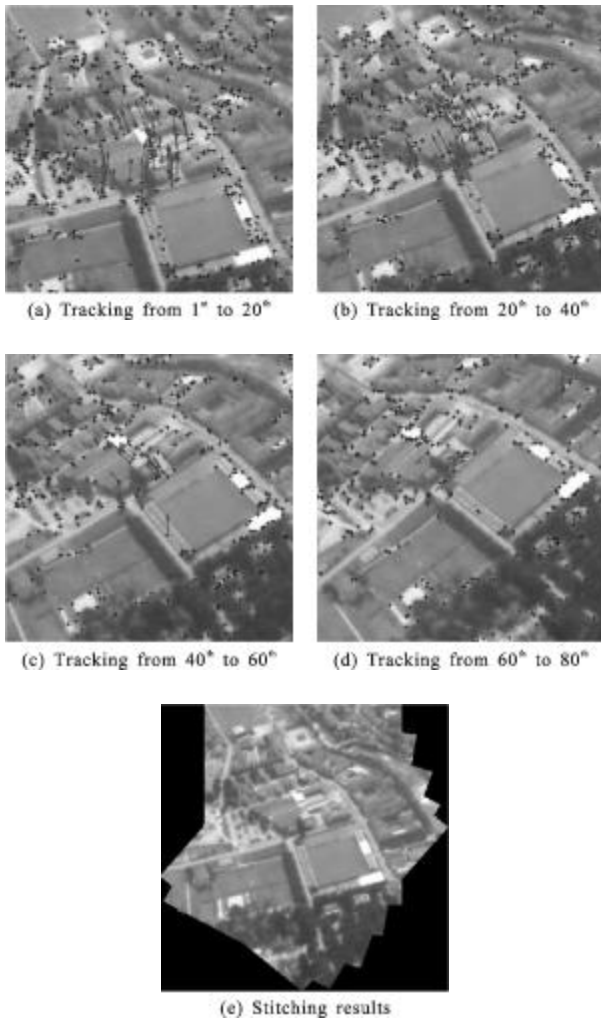


图 12 基于 MC-KLT 的帧间特征点跟踪(Baseline=20)  
Fig.12 Feature points tracking using MC-KLT (Baseline=20)

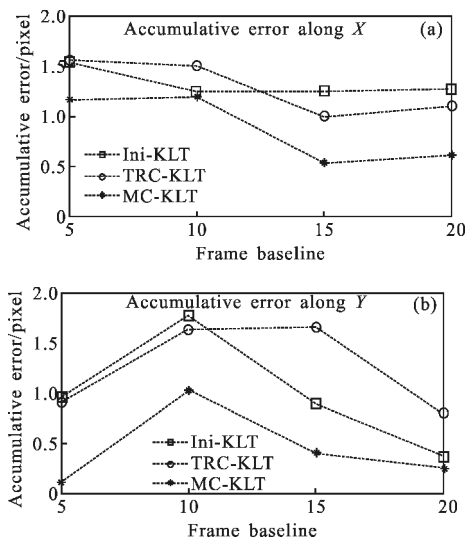


图 13 不同序列的多帧跟踪  
Fig.13 Multi-frame tracking in different sequences

### 4 结 论

针对无人机视频图像帧间运动较大造成帧间的特征点跟踪误差大的问题,文中提出一种基于多重约束的 KLT 特征点跟踪算法。该方法基于时间可逆性约束思想,在求解前向跟踪偏移量的同时利用后向跟踪偏移量构造一种新的偏移量-双向偏移量,在图像的金字塔表示模型下对帧间变化较大的运动进行有效估计。通过对真实航拍视频图像的特征跟踪实验验证了算法的有效性和优越性。

### 参考文献:

- [1] Davide Scaramuzza, Friedrich Fraundorfer. Visual odometry: part I: the first 30 years and fundamentals [J]. IEEE Robotics & Automation Magazine, 2011, 11, 18(4): 80-92.
- [2] Huang Kengyen, TSAI Yimin, TSAI Chihchung, et al. Feature -based video stabilization for vehicular applications [C]//IEEE 14th International Symposium on Consumer Electronics, 2010: 1-2.
- [3] Lowe David G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [4] Li Xiyang, Ni Guoqiang. Optical flow computation of infrared image [J]. Infrared and Laser Engineering, 2002, 31(3): 189-193.
- [5] Muhammad Wasim Nawaz, Abdesselam Bouzerdoum, Son Lam Phung. Optical flow estimation using sparse gradient representation [C]//IEEE 18th International Conference on Image Processing, 2011: 2681-2684.
- [6] Gianpaolo Conte, Patrick Doherty. An integrated UAV navigation system based on aerial image matching[C]//IEEE Conference on Aerospace Conference, 2008:1-10.
- [7] Birchfield S. KLT: An implementation of the kanade-lucas-tomasi feature tracker [EB/OL]. <http://www.ces.clemson.edu/stb/klt>, 2005-11.
- [8] Hao Wu, Chellappa R, Sankaranarayanan A C, et al. Robust visual tracking using the time-reversibility constraint[C]//IEEE International Conference on Computer Vision, 2007.
- [9] Shi J, Tomasi C. Good features to track [C]//IEEE Conference on Computer Vision and Pattern Recognition, 1994: 593-600.
- [10] Zdenek Kalal, Krystian Mikolajczyk, Jiri Matas. Forward-backward error: automatic detection of tracking failures [C]//International Conference on Pattern Recognition, 2010: 2756-2759.