

# 基于有向模板和颜色加权 SVD 的图像匹配算法

康海洋<sup>1),2)</sup> 王杰生<sup>1)</sup> 何国金<sup>1)</sup>

<sup>1)</sup>(中国科学院对地观测与数字地球科学中心重点实验室,北京 100086) <sup>2)</sup>(中国科学院研究生院,北京 100039)

**摘要** 为快速稳定地匹配视频序列,并考虑 SVD 算法的高效性,根据视频序列的特点,对 SVD 匹配算法进行改进,提出了一种适合视频序列的匹配算法。该算法使用 Harris 角点检测算子检测兴趣点,使用有向模板提取具有旋转不变性的特征,并通过引入颜色加权法改进 SVD 算法中的相似性度量函数。同时,又提出一种基于运动一致性约束的误配点剔除方法,首先拟合匹配点间的运动模型,然后自适应地调整参数将错误的匹配点剔除。该算法使用有向模板消除图像间旋转变换的影响,使用颜色特征降低兴趣点匹配时的不确定性,通过运动一致性约束降低误配点数量。实验结果表明,该算法在图像间存在旋转变换关系和不同的光照条件时都可以获得很好的匹配结果,特别是在图像间基线距离较大时仍能得到大量的匹配点并具有很高的正确匹配率,能很好满足实际需要。

**关键词** 图像匹配 有向模板 颜色加权 运动一致性 奇异值分解

中图法分类号:TP391.41 文献标识码:A 文章编号:1006-8961(2008)06-1177-08

## Image Matching Algorithm Based on Oriented-patch and Color-weighted SVD

KANG Hai-yang<sup>1),2)</sup>, WANG Jie-sheng<sup>1)</sup>, HE Guo-jin<sup>1)</sup>

<sup>1)</sup>(Key Laboratory, Center for Earth Observation and Digital Earth, Chinese Academy of Sciences, Beijing 100086)

<sup>2)</sup>(Graduate School of Chinese Academy of Sciences, Beijing 100039)

**Abstract** In order to match video sequence images efficiently and considering the effectiveness and efficiency of the SVD matching algorithm, this paper describes a more advanced SVD multi-view video image matching algorithm based on a new type of invariant feature and outlier rejection strategy. The features are located at Harris corners and oriented using a blurred local gradient. This defines a rotationally invariant frame which is sampled as a feature descriptor. The color information is introduced into the distance function of SVD matching algorithm. The outliers are rejected based on motion consistency. For motion consistency a motion model was fit first between the matched points, and the threshold was set adaptively using the deviations of the motion to reject the outliers. This algorithm uses oriented-patch to adapt to the effect of rotation, color features to remove the uncertainty, and motion consistency to increase the correct match ratio. The experimental results show that the algorithm can obtain lots of matching points between wide base line images, even if there is rotational transformation and different lighting conditions between two images, which proof that the algorithm has practical value.

**Keywords** image matching, oriented-patch, color-weighted, motion consistency, singular value decomposition

## 1 引言

图像匹配是计算机视觉领域的一个基本问题,

一直是人们研究的热点和难点,它是在来自不同时间、不同传感器或者不同视角的同一场景的两幅或多幅图像之间寻找对应关系。由于拍摄时间、拍摄角度、自然环境的变化,多种传感器的使用、传感器

基金项目:国家自然科学基金项目(60272032);中国科学院中国遥感卫星地面站创新项目(062103)

收稿日期:2006-07-18;改回日期:2007-01-08

第一作者简介:康海洋(1982~),男。中国遥感卫星地面站信号与信息处理专业硕士研究生。主要研究方向为遥感图像智能处理、计算机视觉。E-mail:hykang@ne.rsgs.ac.cn

本身的缺陷及噪声的影响,拍摄的图像会存在灰度失真和几何畸变,在这种条件下,如何使匹配算法精度高、正确匹配率高、速度快和抗干扰性强成为人们关心的问题<sup>[1]</sup>。

图像匹配算法大体上可以分为两大类:直接法和基于图像特征法。直接法首先建立一个误差模型,然后使用一定的搜索策略寻找具有最小误差的图像间变换关系,这类算法的计算量较大。基于特征法检测图像边、角等特征并提取特征所在位置的局部区域,用该区域计算特征间的相似度并确立图像间的对应关系,这类方法计算量小且易于实现<sup>[2,3]</sup>。

使用直接法的最大缺点就是它很难收敛,在实际的系统中效果并不是很理想<sup>[3]</sup>。而近年来,由于基于图像特征匹配算法的良好性能,这类算法得到广泛的研究。考虑到视频序列匹配的数据量,本文采用基于特征的匹配算法,并根据视频序列的特点,对当前的基于图像特征匹配算法进行了总结和改进,提出了一种适合视频序列的基于SVD的图像匹配算法。该算法从特征提取和特征匹配这两个角度对SVD匹配算法进行了改进,使用有向模板提取具有旋转不变性特征,在特征匹配过程中引入颜色加权,最后利用运动一致性约束剔除误配点。

## 2 使用奇异值分解进行特征匹配

Pilu将前人提出的用奇异值分解(SVD)匹配图像方法进行了改进<sup>[4]</sup>,该算法主要分3部分:

设 $I$ 和 $J$ 为两幅灰度图像,分别在这两幅图像中提取 $m$ 和 $n$ 个特征:

$$I_i = (d_1^i, d_2^i, \dots, d_k^i) \quad (i = 1, 2, \dots, m)$$

$$J_j = (d_1^j, d_2^j, \dots, d_k^j) \quad (j = 1, 2, \dots, n)$$

式中, $k$ 是特征向量的维数,每个特征对应着图像中的一个 $w \times w$ 区域, $w$ 为区域大小。寻找特征之间的对应关系分为3步:

(1)建立特征间相似度矩阵 $G$ :

$G$ 中的每个元素 $G_{i,j}$ 为两个特征 $I_i, J_j$ 间的高斯加权距离:

$$G_{i,j} = \frac{G_{i,j} + 1}{2} e^{-r_{i,j}^2 / 2\sigma^2} \quad i = 1, \dots, m; j = 1, \dots, n$$

式中, $G_{i,j} = \frac{\sum_{l=1}^k (d_l^i - \mu^i)(d_l^j - \mu^j)}{k\sigma(I_i)\sigma(J_j)}$ ,  $\mu^i, \mu^j$ 为特征

$I_i, J_j$ 的均值, $\sigma(I_i), \sigma(J_j)$ 为 $I_i, J_j$ 的方差。 $r_{i,j} = \|I_i - J_j\|$ 为两个特征 $I_i, J_j$ 间的欧氏距离。

(2)对相似度矩阵 $G$ 进行奇异值分解:

$$G = UDV^T$$

式中, $U$ 为 $m$ 阶正交方阵, $V$ 为 $n$ 阶正交方阵, $D$ 为 $m \times n$ 对角阵,对角元素为矩阵 $G$ 的奇异值,并按降序排列。如果 $m < n$ ,只有 $U$ 的前 $m$ 列有意义。

(3)计算一个新的相似度矩阵:

$$P = UEV^T$$

$$\text{其中, } E_{i,j} = \begin{cases} D_{i,j} & i \neq j \\ 1 & i = j \end{cases}$$

如果矩阵 $P$ 中的元素 $P_{i,j}$ 既是 $i$ 行中的最大值,又是 $j$ 列中的最大值,那么特征点 $i$ 和 $j$ 就为对应点。

Pilu的实验表明,奇异值分解匹配方法在图像间的基线距离较小的情况下有较好的匹配结果,但随着基线距离的增大,误配率会不断增加,导致Pilu算法在基线距离增大情况下表现不好的原因并不是奇异值分解匹配方法的问题,而是选择的图像特征不够稳健。本文通过使用有向模板和利用RGB3个波段信息,构造具有旋转不变性的特征向量,并使用颜色加权距离公式降低匹配时的不确定性,增加了SVD算法的适用范围并改善了匹配结果。

## 3 有向特征向量提取

### 3.1 兴趣点检测

本文使用Harris角点检测算子检测角点<sup>[2,5]</sup>。Harris角点检测算子一直被图像匹配研究者广泛使用,它有很多吸引人的性质,比如旋转不变性等,且计算速度快,实现简单。Harris角点检测算子以局部区域的自相关矩阵为基础。设有1幅灰度图像 $I$ ,图像中各点 $(x, y)$ 的自相关矩阵为

$$H = \nabla_{\sigma^d} P(x, y) [\nabla_{\sigma^d} P(x, y)]^T * g_{\sigma^d}(x, y) \quad (1)$$

式中, $\nabla_{\sigma^d} P(x, y) = \nabla P(x, y) * g_{\sigma^d}(x, y)$ ,  $\nabla P(x, y)$ 是 $P(x, y)$ 的空域梯度, $g_{\sigma^d}(x, y)$ 是尺度为 $\sigma^d$ 的高斯平滑滤波器, $\sigma$ 为高斯滤波器方差, $d$ 为向量维数,\*代表卷积。上标T代表矩阵的转置。这样得到的自相关矩阵是一个 $2 \times 2$ 对称矩阵。

定义点 $(x, y)$ 处的角特征响应为矩阵 $H$ 的两个特征值的调和平均,即

$$f(x,y) = \frac{\det \mathbf{H}}{\text{tr} \mathbf{H}} = \frac{\lambda_1 \lambda_2}{\lambda_1 + \lambda_2} \quad (2)$$

式中,  $\text{tr} \mathbf{H} = H_{11} + H_{22} = \lambda_1 + \lambda_2$ , 是矩阵  $\mathbf{H}$  两个对角元素  $H_{11}, H_{22}$  的和。  $\det \mathbf{H} = H_{11}H_{22} - (H_{12})^2 = \lambda_1 \lambda_2$ , 是矩阵  $\mathbf{H}$  的行列式,  $\lambda_1, \lambda_2$  是矩阵  $\mathbf{H}$  的特征值。如果图像中点  $(x, y)$  的角特征响应  $f(x, y)$  是所在  $3 \times 3$  区域中的最大值, 那么就将该点标记为兴趣点。

### 3.2 兴趣点过滤

兴趣点过滤的目的是调整兴趣点的空间分布及剔除位于边界上的不稳定兴趣点。本文通过控制兴趣点间的距离使兴趣点较均匀分布在图像中, 同时使用 Lowe 的方法<sup>[6]</sup>剔除边界上不感兴趣点。

设兴趣点数目为  $n$ , 将检测到的兴趣点按角点响应值降序排列得到兴趣点序列  $p(i) (i = 1, \dots, n)$ 。设两个兴趣点之间的距离  $\text{dist}(i, j) = \|p(i) - p(j)\|$ , 并设定阈值  $T$ 。对每个兴趣点  $p(i) (i = 1, \dots, n)$ , 如果  $\text{dist}(i, j) < T (j = 1, \dots, i - 1)$ , 就将  $p(i)$  从兴趣点列上剔除。实验结果显示, 当  $T = 10$  时, 兴趣点可以较均匀分布在图像间的重合区内。如果将  $T$  减小, 在纹理丰富的区域会保留过多兴趣点, 出现兴趣点聚集现象。而增大  $T$  会导致兴趣点数目过少, 不能满足很多应用的需要。

在利用图像的局部特征进行匹配时, 边界特征特别是直线边界特征会给匹配带来不确定性。设图像中一点  $(x, y)$  的自相关矩阵为  $\mathbf{H}$ , 其绝对值最大的特征值为  $\lambda_1$ , 绝对值最小的特征值为  $\lambda_2$ , 它们之间的比率关系为  $\lambda_1 = \rho \lambda_2$

$$\begin{aligned} \frac{[\text{tr} \mathbf{H}]^2}{[\det \mathbf{H}]} &= \frac{(\lambda_1 + \lambda_2)^2}{\lambda_1 \lambda_2} \\ &= \frac{(\rho \lambda_2 + \lambda_2)^2}{\rho \lambda_2^2} = \frac{(\rho + 1)^2}{\rho} \end{aligned} \quad (3)$$

上式在两个特征值相等时有最小值, 并随着  $\rho$  的增大而增大。因此令

$$\frac{[\text{tr} \mathbf{H}]^2}{[\det \mathbf{H}]} < \frac{(\rho + 1)^2}{\rho} \quad (4)$$

$\rho$  的取值对匹配结果影响较大。实验结果显示, 当  $\rho = 5$  时, 得到的兴趣点比较稳定。实验结果如图 1 和图 2 所示, 实验使用了 4 组图像数据。图 1 是各组数据在不同  $\rho$  值时检测到匹配点数目, 该数值已被归一化。图 2 是各组图像检测到的归一化匹配点数目的平均值。




图 1 参数对匹配结果的影响  
Fig. 1 Parameter's effect




图 2 归一化影响曲线  
Fig. 2 Normalized curves

### 3.3 兴趣点的精确位置

为了使计算结果更加稳定, 兴趣点位置需要被定位到亚像素精度。本文使用 Shaun 等人提出的拟合二次曲面方法获取兴趣点的精确位置<sup>[7]</sup>。二次曲面以图像坐标为定义域, 角特征响应为值域, 用方程可以表示成如下形式:

$$z(x,y) = ax^2 + by^2 + cxy + dx + ey + f$$

式中,  $a, b, c, d, e, f$  为未知系数。

选取特征点周围  $3 \times 3$  区域的 9 个点可以构造一个超定方程, 通过最小二乘法可以求得未知数。计算二次曲面  $x, y$  方向的梯度并置零, 最后可得兴趣点的精确坐标为  $(x + x_\sigma, y + y_\sigma)$ , 其中,  $x_\sigma = \frac{2db - ce}{c^2 - 4ab}, y_\sigma = \frac{2ae - dc}{c^2 - 4ab}$ ,  $(x, y)$  是 Harris 算子检测到的兴趣点坐标。

### 3.4 兴趣点的方向

为了提取到具有旋转不变性的图像特征, 一个简单的方法就是先对采样模板进行旋转, 然后使用旋转后的模板进行特征提取。模板的旋转角度由兴

趣点处的梯度计算。设点  $(x, y)$  处的梯度为  $\mathbf{grad} x$ 、 $\mathbf{grad} y$ ，梯度的模  $m = \sqrt{(\mathbf{grad} x)^2 + (\mathbf{grad} y)^2}$ ，则  $\cos\theta = \frac{\mathbf{grad} x}{m}$ ， $\sin\theta = \frac{\mathbf{grad} y}{m}$ 。构造旋转矩阵  $R$  为

$$R = \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (5)$$

有向模板的一个缺点就是受噪声干扰比较大，旋转角度的微小偏差就会导致最后匹配的失败。Matthew Brown 等人建议对图像进行适当的平滑滤波<sup>[2]</sup>。本文算法使用高斯平滑滤波器，实验证明，滤波器大小为  $19 \times 19$ ，方差为 5 时，结果比较稳定。实验结果如图 3 所示，纵坐标为匹配点个数，横坐标是滤波器模板大小，颜色代表方差。实验数据是从一段视频中提取的两个基线距离很大的两帧图像。

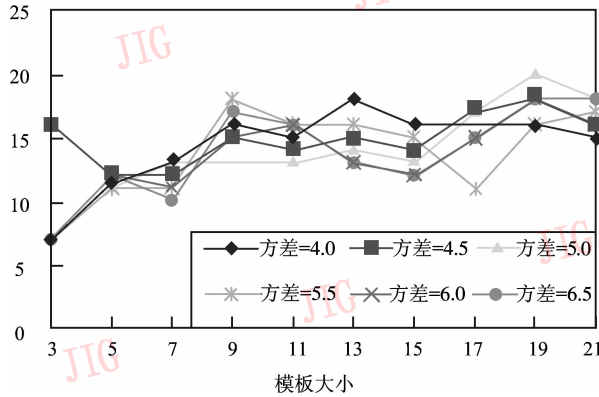


图 3 不同滤波器对匹配点数的影响  
Fig. 3 Different filters' effect

### 3.5 有向特征向量提取

确定兴趣点的位置和方向后，下一步就是提取特征向量。特征向量是匹配算法中最为关键的因素，Matthew Brown 等人通过实验证明通过增大模板和采用间隔采样可以得到很好的匹配结果<sup>[2]</sup>。借鉴上述方法，本文算法首先建立一个  $40 \times 40$  的采样模板  $W$ ，并设  $W$  的初始方向为向上。对每个兴趣点，用与之对应的旋转矩阵变换采样模板得到新的采样模板  $W_n = RW$ 。对于所有的兴趣点来说，这样得到的采样模板具有一致的参考方向，因而特征向量具有旋转不变性。用模板  $W_n$  可以在特征点周围采样到  $40 \times 40$  大小的区域  $F$ ，如果直接把  $F$  作为特征进行匹配，计算量会很大，因此需要对  $F$  进行重采样以降低维数。将

$F$  每 5 个像素采样一次并变换成行向量，这样就得到一个 64 维特征向量  $d$ 。为了消除图像的增益和偏差的影响，特征向量  $d$  被归一化。归一化后的特征向量  $\tilde{d} = (d - \mu) / \delta$ ，其中  $d = (d_1, d_2, \dots, d_n)$  ( $n = 64$ )，特征向量的均值  $\mu = \frac{1}{n} \sum_{y=1}^n d_i$ ，特征向量的标准方差  $\delta = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - \mu)^2}$ 。虽然理论上提取到的特征向量具有旋转不变性，但角点检测算子的局限性和实际图像内容变化的不确定性限制了算法的适应范围，使得算法只能在一定的旋转角度内获得比较实用的匹配结果。图 4 是不同旋转角度对算法的影响曲线。实验数据是通过不断旋转相机得到的。针对某一目标，渐增旋转角度，每次增加量为 3 度左右，共采集了 5 组图像数据，图像大小为  $410 \times 307$ ，各组实验均有 100% 的正确率。由数据 4 可见，当旋转角度超过 15° 时，匹配结果会有所波动，但算法仍然可以找到大概 20 个左右的匹配点，证明了本文算法中使用的特征可以在一定程度上消除图像间旋转的影响。




图 4 旋转角度对匹配结果的影响  
Fig. 4 Different angles' effect

### 3.6 颜色加权距离

在图像匹配中，遮掩现象会给匹配过程带来很大的不确定性进而导致匹配错误。同时，由于图像内信息的复杂和随机性，很多不同物体会在图像中生成非常类似的灰度图像。通常在遮掩的边缘处会造成颜色的突变，而不同的物体可能具有不同的颜色。因此，在图像匹配中利用颜色特征会改善匹配的结果<sup>[8]</sup>。但由于颜色受光照，视点位置等因素影响较大，使用全部颜色信息，在图像间的基线距离较大时，会增加匹配时的不确定性和计算量。为解决上述问题，本文使用有向大

模板及低采样率提取颜色特征。设有彩色图像  $I$ , 其 3 个波段的值分别为  $I_r, I_g, I_b$ , 以兴趣点  $i$  为中心, 使用间隔为 5 的  $20 \times 20$  的模板在兴趣点周围从  $I_r, I_g, I_b$  分别提取  $8 \times 8$  的颜色特征, 并构造 3 组 64 维颜色特征向量  $I_r^i, I_g^i, I_b^i$ , 上标  $i$  代表兴趣点  $i$  的颜色特征向量。

最后将 Pilu 算法中的特征间距离计算公式修改为

$$G_{i,j} = \frac{G_{i,j} + 1}{2} e^{-r_{i,j}^2/2\sigma_g^2} e^{-y_{i,j}^2/2\sigma_c^2}$$

其中,  $r_{i,j} = \|r_i - r_j\|$  是使用两个兴趣点的灰度特征计算的欧氏距离,  $y_{i,j} = \sum_{c \in \{r,g,b\}} |I_c^i - I_c^j|$ , 是两个兴趣点间颜色特征的绝对差异。

### 4 误配点剔除

上述兴趣点匹配算法的基础是兴趣点之间的相似性。由于图像内容的复杂性和外界噪声的干扰, 这种方法不可避免的存在误差。为了提高正确匹配率, 本文提出一种运动一致性约束方法来剔除误配点。运动一致性是指所有的匹配点之间具有一致的位置偏移量  $\Delta u_{i,j}$  和角度偏移量  $\Delta \theta_{i,j}$ 。设在两幅图像  $I$  和  $J$  中有一组匹配点  $\{(x_i, y_i), (x_j, y_j)\}$ , 并设对应的角度为  $(\theta_i, \theta_j)$ , 其中  $x, y$  为点的图像坐标,  $i, j$  是匹配点标号。则  $\Delta u_{i,j} = (\Delta x_{i,j}, \Delta y_{i,j}) = (x_i - x_j, y_i - y_j)$ ,  $\Delta \theta_{i,j} = \theta_i - \theta_j$ 。以图像  $I$  为参考图像, 并将在  $I$  中的点坐标  $(x_i, y_i)$  变换为 1 维形式即  $\hat{x}_i = (x_i - 1) \times column + y_i$ , 其中,  $column$  为图像的宽度, 对坐标进行这样处理可以简化运动模型的拟合过程。实验数据显示, 在以  $\hat{x}_i$  为输入,  $\Delta x_{i,j}, \Delta y_{i,j}, \Delta \theta_{i,j}$  为输出时, 位置偏移量和角度偏移量几乎在同一条直线上, 如图 5 所示, 3 幅图分别是  $\Delta x_{i,j}, \Delta y_{i,j}, \Delta \theta_{i,j}$  以  $\hat{x}_i$  为横坐标时候的分布情况, 点集为运动偏移量, 其中标记方框的点是剔除的误配点。

可以假设偏移量  $\Delta_i = a + b \times \hat{x}_i$ , 即坐标和偏移量之间是线性关系, 其中,  $\Delta_i = \{\Delta x_{i,j}, \Delta y_{i,j}, \Delta \theta_{i,j}\}$ 。拟合上述线性关系有很多方法, 本文采用稳健线性拟合方法<sup>[9,10]</sup>。为有效剔除误配点, 根据拟合的误差计算各对匹配点的可信度  $credit_i^m = -e^{-error_i^m/2}$ , 其中,  $error_i^m$  为各匹配点的拟合误差,  $m = \{x, y, \theta\}$ , 代表 3 种运动方式。如果  $credit_i^m > thresh_i^m$ , 就将该对匹配点保留, 相

反则剔除。由于图像间运动的不可预测性, 单纯的通过统一阈值过滤匹配点不能得到很好的结果, 本文提出一种根据偏移量方差自适应的调整阈值的方法。首先计算偏移量  $\Delta_i = \{\Delta x_{i,j}, \Delta y_{i,j}, \Delta \theta_{i,j}\}$  的方差  $\sigma_i = \{\sigma x_{i,j}, \sigma y_{i,j}, \sigma \theta_{i,j}\}$ 。数据的方差度量了数据的离散程度, 小的方差表示数据密集度高, 能更好的用线性模型拟合。因此, 赋予小方差运动大的权值  $\eta_i^m$ , 赋予大方差运动小的权值, 最后设定  $thresh_i^m = \eta_i^m \times \max(credit_i^m)$ 。




图 5 运动拟合  
Fig. 5 Motion fit

### 5 实验分析

#### 5.1 图像对实验

图 6 是 ~ 图 9 是在不同场景通过旋转相机拍摄的图像对。图 10 是两幅有仿射变换关系的图像。图 11 是两幅具有不同光照条件的图像。这些图像的大小都是  $410 \times 307$ 。表 1 和表 2 分别统计了本文算法和原 SVD 算法的匹配结果。从表 1 中可以看出,本文算法对旋转、少量仿射变换及光照变化有一定的适用性,每组实验都获得了较多匹配点并具有很高的正确匹配率,但在图像中存在较大仿射变换时,匹配点的数目和正确率会有所下降。从表 2 中可以看出,原 SVD 匹配算法虽然能找到很多匹配点,但错误率太高,在图像中存在旋转时,算法几乎失效。



(a) 图像1(图像大小 $410 \times 307$ )



(b) 图像2(图像大小 $640 \times 480$ )



(c) 图像3(图像大小 $410 \times 307$ )

图 6 旋转

Fig. 6 Rotation




图 7 旋转 + 仿射(图像大小  $800 \times 640$ )

Fig. 7 Rotation with affine



图 8 仿射 + 透视效应(图像大小  $800 \times 640$ )

Fig. 8 Affine transformation with Foreshortening



图 9 不同光照条件(图像大小  $900 \times 600$ )

Fig. 9 Different lighting condition

表 1 本文结果

Tab. 1 Result of this paper

	图 2	图 3	图 4	图 5	图 6	图 7
匹配点数	46	82	40	102	49	35
错点数	0	0	0	2	9	1

表 2 原 SVD 算法结果

Tab. 2 Original result

	图 2	图 3	图 4	图 5	图 6	图 7
匹配点数	64	100	76	300	291	189
错点数	25	40	50	289	287	151

#### 5.2 视频序列实验

实验数据是从视频序列中提取的数帧图像(间隔有 1s 左右),用第 1 帧图像与其他图像匹配,并通过两个指标评估算法的性能:

(1)检测到匹配点数目:算法检测出的对应点的总数。

(2)正确匹配率:正确对应点数/检测到匹配点数目。

图 10(a) ~ (g) 分别为第 1 ~ 7 段视频序列的第 1 帧图像,图像大小均为  $410 \times 307$ 。

图 10 中,视频 1 内景物为室内书架,图像间存在平移及旋转变换。视频 2 到视频 7 为室外景物,图像间存在旋转和少量的仿射变换。图 11 和图 12



(a) 视频1

(b) 视频2

(c) 视频3



(d) 视频4



(e) 视频5



(f) 视频6



(g) 视频7

图 10 视频

Fig. 10 Video

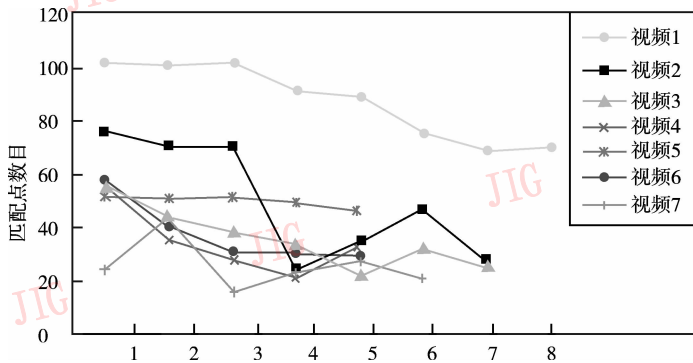


图 11 检测到匹配点数目

Fig. 11 Number of matched point




图 12 正确匹配率

Fig. 12 Ratio of correctness

分别是检测到的匹配点数目和匹配正确率。这两幅图的横坐标是视频中不同两帧图像组成的图像对的序号。从图中可以看出,本文算法在图像间有平移、旋转、少量仿射变换时,可以找到很多匹配点,并具

有很高的正确率,证明了算法的有效性。

虽然实验中将匹配点数目作为评价算法的一个指标,但在实际应用中匹配点数目不一定是越多越好,因为不同的应用目的对匹配点数量要求不同,比

如进行 3 维重建对匹配点的数目需求就很大;而如果是要估计摄像机的相对位置,只要十几个匹配点就可以完成任务。当然,总体来说正确匹配点数目越多,说明匹配算法的性能越好。

## 6 结 论

本文提出了一种改进的基于 SVD 的图像匹配算法。算法使用有向模板和颜色特征进行兴趣点之间的匹配,利用相关性约束、颜色一致性约束和运动一致性约束降低匹配时的不确定性,使原 SVD 算法的性能得到了极大的提高。特别是运动一致性约束的使用,大量地剔出了错误匹配点,使算法获得极高的正确匹配率。大量实验结果表明,本文算法在图像间存在平移、旋转和少量仿射变换时具有很高的正确匹配率和稳定的匹配结果,能快速地在视频序列间进行匹配,很好地满足实际需要。为了进行 3 维场景重建,本文算法可以作为重建过程的初始准备阶段,即进行初始匹配,在此基础上可以通过核线约束技术,进行二次图像匹配以获取精度更高,密度更大的匹配结果。

### 参考文献 (References)

1 Wang Hong-mei Zhang Ke Li Yan-ju. Research progress on image matching [ J ]. Computer Engineering and Applications, 2004, 40 ( 19 ): 42 ~ 44, 77. [ 王红梅, 张科, 李言俊. 图像匹配研究进

展 [ J ]. 计算机工程与应用, 2004, 40 ( 19 ): 42 ~ 44, 77. ]

2 Brown M, Szeliski R, Winder S. Multi-image matching using multi-scale oriented patches [ A ]. In: Proceedings of the 2005 IEEE Computer Society International Conference on Computer Vision and Pattern Recognition [ C ], San Diego, CA, USA, 2005: 510 ~ 517.

3 Szeliski R. Image alignment and stitching [ M ]. Paragios N, Chen Yun-mei, Faugeras O. Handbook of Mathematical Models in Computer Vision, Springer-verlag, 2005: 273 ~ 292.

4 PILU M. A direct method for stereo correspondence based on singular value decomposition [ A ]. In: Proceedings of Computer Society Conference on Computer Vision and Pattern Recognition [ C ], San Juan, Puerto Rico, USA, 1997: 261 ~ 266.

5 Harris C, Stephens M. A combined corner and edge detector [ A ]. In: Proceedings of Fourth Alvey Vision Conference [ C ], Manchester, UK, 1988: 147 ~ 151.

6 Lowe D G. Distinctive image features from scale-invariant keypoints [ J ]. International Journal of Computer Vision, 2004, 60 ( 2 ): 91 ~ 110.

7 Gleason S S, Hunt M A, Jatko W B. Subpixel measurement of image features based on paraboloid surface fit [ J ]. SPIE, 1990, 1386: 135 ~ 144.

8 Yang Q, Wang L, Yang R, *et al.* Stereo matching with color-weighted correlation, hierarchical belief propagation and occlusion handling [ A ]. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition [ C ], New York, NY, USA, 2006: 2347 ~ 2354.

9 Szeliski R. Computing and graphics in statistics [ M ], New York: Springer-Verlag, Inc, 1992: 41 ~ 48.

10 Holland P W, Welsch R E. Robust regression using iteratively reweighted least-squares [ J ]. Communications in Statistics: Theory and Methods, 1977, A ( 6 ): 813 ~ 827.