

引用格式:卢健,陈泽民,马成贤,等.分块多项式确定性矩阵SIFT图像配准算法[J].电光与控制,2019,26(1):12-16.LU J, CHEN Z M, MA C X, et al. An SIFT image registration algorithm based on block polynomial deterministic matrix[J]. Electronics Optics & Control, 2019, 26(1):12-16.

## 分块多项式确定性矩阵SIFT图像配准算法

卢健, 陈泽民, 马成贤, 何金鑫  
(西安工程大学电子信息学院, 西安 710048)

**摘要:** 针对尺度不变特征变换(SIFT)算法在关键点(即尺度空间稳定的极值点)特征描述向量计算复杂且维数较高, 以及多项式确定性矩阵测量数取值受限等现象, 提出一种分块多项式确定性矩阵的SIFT图像配准算法。通过压缩感知的稀疏表示方法, 将SIFT提取的高维描述子向量降维到低维的稀疏特征向量, 降低了关键点描述向量维度, 并采取欧氏距离对图像关键点特征描述向量进行相似性度量。与传统算法的针对性比对分析表明, 改进算法有效提升了配准精度, 增强了实时性。

**关键词:** 图像配准; SIFT; 分块多项式确定性矩阵; 压缩感知

中图分类号: TN919.8 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.01.003

## An SIFT Image Registration Algorithm Based on Block Polynomial Deterministic Matrix

LU Jian, CHEN Ze-min, MA Cheng-xian, HE Jin-xin

(School of Electronic and Information, Xi'an Polytechnic University, Xi'an 710048, China)

**Abstract:** For the Scale-Invariant Feature Transform (SIFT) algorithm, the eigenvectors at the key points (the extreme points of a stable scale space) are computationally complex and usually have high dimensions, while the values of the polynomial deterministic matrix are limited. To solve the problems, an SIFT image registration algorithm based on the block polynomial deterministic matrix is proposed. The SVM-derived sparse representation method is used to reduce the high-dimensional descriptor vector extracted by SIFT to a low-dimensional sparse feature vector, which reduces the dimensions of key-point description vector. The Euclidean distance is used for similarity measurement of the key-point feature description vector. The contrastive analysis with the traditional algorithms shows that the improved algorithm can effectively improve the registration accuracy and enhance the real-time performance.

**Key words:** image registration; SIFT; block polynomial deterministic matrix; compressive sensing

### 0 引言

图像配准技术在图像处理领域起着至关重要的作用, 例如在图像融合技术得以可靠实现前提下, 配准精度直接影响图像融合的质量。现阶段在配准速度快、实时性好等亮点趋势下, 基于特征提取图像配准方法得以突破性研究和多方面应用。尺度不变特征变换 (Scale-Invariant Feature Transform, SIFT) 最先是在 1999

年由 LOWE 提出, 并在 2004 年进行算法完善<sup>[1-2]</sup>。该算法以图像局部特征的提取实现配准, 首先以重构尺度空间实现极值点的提取, 再筛选出具有平移、旋转、尺度不变性的描述子, 从而提高匹配精度。并在旋转、尺度放缩、对视角转换、放射变换等变换条件下保证了稳定性要求, 同时在光照影响、目标遮挡等因素下保持良好的匹配性, 能很好地实现差异较大图像之间的特征匹配。自问世以来, 在图像配准领域得以多方面应用并推广, 其算法得到不断改进和优化。如 MAHMOUD 等<sup>[3]</sup>提出一种基于聚类分割的 SIFT 医学图像配准, 实现对伪噪声的良好抑制; 文献[4]中极低分辨率的视网膜图像的融合实现采用 SIFT 与最优矩形优化算法 (Best-Bin-First, BBF) 的结合; 文献[5-6]针对遥感图像问题采用了改进的 SIFT 特征匹配技术, 并取得突破性进展。

收稿日期:2018-06-29 修回日期:2018-12-28

基金项目:国家自然科学基金(61040055);陕西省教育厅专项科学  
研究计划项目(17JK0332);陕西省科技厅科技发展计划项目(2011  
K06-01);西安市碑林区应用技术研发项目(GX1807)

作者简介:卢健(1978—),男,河北献县人,博士,副教授,硕导,研  
究方向为 AI 机器人应用创新。

压缩感知(Compressive Sensing, CS)由 CANDES 和 DONOHO 等在 2004 年提出<sup>[6-8]</sup>,突破了传统的香农采样(Nyquist)定理关于信号采样频率不低于信号带宽 2 倍的要求,充分利用信号稀疏性和可压缩性进行信号的采样和解码。CS 理论在信号处理等领域得到广泛的应用:文献[9]将其应用于三维旋转微波成像的重建;文献[10]使用其改进了视觉传感网络图像表示方法;文献[11-12]提出了一种基于压缩感知的图像配准算法。

在压缩感知中,稀疏投影是实现稀疏信号重建的关键,针对现实应用中进一步提高特征提取的有效性和实时性要求,克服确定性矩阵测量数取值范围有限的缺陷,利用分块多项式矩阵,对 SIFT 算法中生成的描述子向量进行稀疏降维,提高所提取特征的匹配精度和匹配速度。

## 1 基本概念

### 1.1 确定性矩阵的生成

假定一个有限域  $F$ ,设定元素个数为  $p$ ,其元素的范围为  $\{0, 1, 2, \dots, p-1\}$ 。在区间  $[0, p]$  上随机给定自然数  $r$ ,定义最高次幂小于或等于  $r$  的多项式集合用  $P_r$  表示,即:  $Q(x) = a_0 + a_1x + a_2x^2 + \dots + a_rx^r, Q(x) \in P_r$ , 其中,  $a_0, a_1, a_2, \dots, a_r \in F$ , 因此共有  $N = P_r + 1$  个多项式。

定义一个大小为  $p \times p$  的零矩阵  $E$ ,且各元素位置为  $\{(0,0), (0,1), (0,2), \dots, (p-1, p-2), (p-1, p-1)\}$ 。把  $x \rightarrow Q(x)$  当作是  $F \rightarrow F$  的映射(即多项式  $Q(x)$  的自变量和函数都在集合  $F$  中取值,  $(x, Q(x)) \in \{0, 1, 2, \dots, p-1\}^2$ ),在矩阵  $E$  的每一列的某一个位置插入数值 1,矩阵  $E$  的第  $x$  列第  $Q(x)$  位置值变化为 0→1,再将矩阵  $E$  转换为  $M \times 1$  的列向量  $v_q$ ,其中,  $M = p^2$ 。

列向量  $v_q$  中,首元素至第  $p$  个元素中有且仅有一个 1,至第  $2p$  个元素中有两个 1,同规律下类推, $v_q$  中总计  $p$  个 1。多项式系数确定后,形成  $N = P_r + 1$  个列向量  $v_q$ 。将  $N$  个  $M$  维列向量组合为  $M \times N$  矩阵(记作  $\Phi_0$ )则矩阵  $\Phi_B = (1/\sqrt{p})\Phi_0$  满足以  $\delta = (k-1)r/p$  为常数的 RIP 性质<sup>[13]</sup>,其中,  $k < p/k + 1$ 。

### 1.2 分块确定性矩阵的生成

由于  $p$  值取自于素数域,  $p$  值越大,矩阵构造时间随之越长,导致  $p$  值取值不能过大,由上述式  $M = p^2$  可知,  $p$  值的大小决定矩阵的构造时间,所以  $p$  取值较小,构造的分块多项式确定性矩阵为

$$\Phi = \begin{bmatrix} \Phi_B & & \\ & \ddots & \\ & & \Phi_B \end{bmatrix} \quad (1)$$

假设在  $\Phi$  中共有  $D$  个  $\Phi_B$ ,则矩阵  $\Phi$  满足以参数  $\delta = \max_{i=1,2,\dots,D} \delta_i, k < D(p/r + 1)$  的 RIP 性质,其中最大值  $\delta_i = D(p/r + 1), k_i < p/r + 1$ 。

式(1)中,  $\Phi$  矩阵的构造不受  $p$  值取值限制,且  $p$  取值较小时可以更快速地构造分块多项式矩阵,极大地节省了矩阵构造的时间。

## 2 分块多项式确定性矩阵 SIFT 配准算法

分块确定多项式矩阵 SIFT 配准算法实现主要分 5 个步骤:1) 构造尺度空间与极值检测;2) 稳定的关键点筛选;3) 关键点主方向分配;4) 基于分块确定性矩阵的描述子生成;5) 描述子的度量和匹配。

### 2.1 尺度空间的构造和极值点检测

在构造图像尺度空间  $L(x, y, \sigma)$  时,用该图像  $I(x, y)$  的卷积运算与可变尺度的高斯函数  $G(x, y, \sigma)$  的乘积来定义  $L(x, y, \sigma)$ 。即

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (2)$$

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} \exp(-\frac{x^2 + y^2}{2\sigma^2}) \quad (3)$$

式中:坐标  $(x, y)$  为像素坐标;参数  $\sigma$  为尺度大小,图像平滑程度直接由  $\sigma$  大小决定。定义两个临近的尺度高斯函数之差为高斯差分 DoG 尺度空间,并与原始图像作卷积运算,计算得到

$$D_{\text{DoG}}(x, y, k\sigma) = G(x, y, \sigma) * I(x, y) \quad (4)$$

$$D_{\text{DoG}}(x, y, k\sigma) = D_{\text{DoG}}(x, y, k\sigma) \otimes I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (5)$$

根据高斯拉普拉斯算子  $L_{\text{DoG}}(x, y, \sigma) = \sigma^2 \nabla^2 G$  的尺度规范性,利用其尺度不变性

$$G(x, y, k\sigma) - G(x, y, \sigma) \approx (k-1)\sigma^2 \nabla^2 G \quad (6)$$

即

$$(k-1)L_{\text{DoG}}(x, y, \sigma) \approx D_{\text{DoG}}(x, y, \sigma) \quad (7)$$

LoG 尺度不变特征点的寻找等价于 DoG 尺度空间内的特征点的寻找。

### 2.2 稳定的关键点筛选

在尺度空间上,通过对 DoG 函数的 Taylor 展开式

$$D(X) = D + \frac{\partial D^T}{\partial X}X + \frac{1}{2}X^T \frac{\partial^2 D}{\partial X^2}X \quad (8)$$

对 DoG 函数进行曲线拟合。代入  $X = (x, y, \sigma)$ ,得到函数极值点  $\hat{X}$ ,并通过将其代入式(4),得出极值点的函数拟合值  $D(\hat{X})$ ,有

$$D(\hat{X}) = D + \frac{1}{2} \frac{\partial D^T}{\partial X} \hat{X} \quad (9)$$

对  $D(\hat{X})$  值进行计算,经实验后将小于某个阈值点的数值排除,阈值点为 0.04。

针对边缘响应点的寻找和滤除,需要在位置尺度  $2 \times 2$  的 Hessian 矩阵计算该点的主曲率,其导数由采

样点相邻差值来估计,即

$$\mathbf{H}(x,y) = \begin{bmatrix} D_{xx}(x,y) & D_{xy}(x,y) \\ D_{yx}(x,y) & D_{yy}(x,y) \end{bmatrix} \quad (10)$$

式中, $D_{xx}, D_{yy}, D_{xy}$ 为候选点领域对应位置的像素差分。 $\mathbf{D}$ 的主曲率和 $\mathbf{H}$ 的特征值成正比关系,所以用 $\alpha$ 和 $\beta$ 分别表示最大特征值和最小特征值, $\alpha$ 和 $\beta$ 的比值用 $r$ 表示,即

$$\text{tr}(\mathbf{H}) = D_{xx} + D_{yy} = \alpha + \beta \quad (11)$$

$$\det(\mathbf{H}) = D_{xx}D_{yy} - (D_{xy})^2 = \alpha\beta \quad (12)$$

$$\frac{\text{tr}^2(\mathbf{H})}{\det(\mathbf{H})} = \frac{(\alpha + \beta)^2}{\alpha\beta} = \frac{(r+1)^2}{r} \quad (13)$$

当 $\text{tr}^2(\mathbf{H})/\det(\mathbf{H}) < (r+1)2/r$ 时,对特征点进行保留,反之则滤除, $r$ 的取值是 10。

### 2.3 关键点主方向分配

计算极值点的梯度

$$\text{grad } I(x,y) = \left( \frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right) \quad (14)$$

$$m(x,y) = \sqrt{[L(x+1,y) - L(x-1,y)]^2 + [L(x,y+1) - L(x,y-1)]^2} \quad (15)$$

$$\theta = \arctan \frac{L(x,y+1) - L(x,y-1)}{L(x+1,y) - L(x-1,y)} \quad (16)$$

式中: $m(x,y)$ 为梯度幅值; $\theta(x,y)$ 为梯度方向。选取关键点作为原点,统计一定区域内图像像素在关键点方向做的贡献,生成方向直方图,直方图以 $20^\circ$ 为 1 柱,共 18 个柱。柱的方向代表 $\theta(x,y)$ ,柱的高度代表 $m(x,y)$ 。原点主方向为直方图的主峰值,大于等于主峰值 80% 的峰值为辅助方向。

### 2.4 基于分块确定性矩阵的描述子生成

关键点主方向分配完成后,其每个关键点都具有了位置、尺度、方向,然后通过用一组向量进行关键点的描述,使其具有描述子的平移、缩放和旋转不变特性<sup>[14]</sup>。

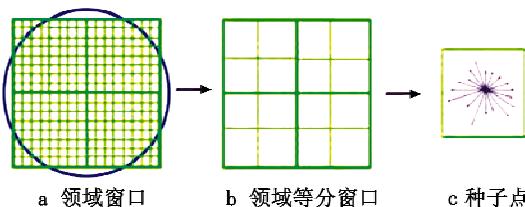


图 1 关键点领域像素的梯度幅值和梯度方向处理过程

Fig. 1 The gradient amplitude and the gradient direction processing of the pixel in the key domain

为了保证旋转不变性,将坐标轴与关键点尺度的主方向保持一致。形成一个以关键点为中心的 $16 \times 16$ 领域窗口,如图 1a 所示。图中,每个小格代表关键点领域窗口在尺度空间上的一个像素,假设像素为 $L(x,y)$ , $(x,y)$ 则表示该像素位置。将 $16 \times 16$ 的领域窗口按 $4 \times 4$ 进行 16 等分,如图 1b 所示,每一小格代表一个种子点,其像素梯度方向范围为 $0^\circ \sim 360^\circ$ 。为了增强匹配的稳定

性,对领域以每 $20^\circ$ 为间隔等分为 18 个方向域,按照方向域将种子各像素梯度进行归类,并对归类后的各方向域的梯度幅值进行累加,图 1a 中圆圈代表进行梯度幅值高斯加权的像素范围。各个种子点的梯度幅值与方向如图 1c 所示,箭头方向代表方向域方向,箭头尺寸表示种子点在本方向的梯度幅值。

由上述可得,一个关键点划分为 16 个种子点,而 1 个种子点又有 18 个方向域,因此每个关键特征点产生的 SIFT 特征向量为 288 维。接着对特征向量幅值进行归一化处理来消除光强变化对关键点的影响,使 SIFT 特征向量具有描述子的特性。

进行配准计算时,由于 288 维特征向量计算量大,导致运算时间较长,此时使用稀疏表示对描述子进行降维<sup>[15~18]</sup>。将关键点描述子用 $288 \times 1$  的列向量 $\mathbf{Z}$ 表示,采用 $288 \times 288$  维小波变换基矩阵 $\Psi$ 将描述子稀疏向量 $\mathbf{Z}$ 表示为

$$\mathbf{Z} = \Psi \mathbf{X} \quad (17)$$

将 $\mathbf{Z}$ 中元素用 $z_i$ 表示, $\mathbf{X}$ 中元素用 $x_i$ 表示,基矩阵 $\Psi$ 的行向量用 $\psi_i$ 表示, $i \in \{1, 2, \dots, 288\}$ ,则有

$$z_i = \psi_i \mathbf{X} = \sum_{j=1}^{288} \psi_{ij} x_j \quad (18)$$

由此, $\mathbf{X}$ 也是 $288 \times 1$  维的列向量,用 $K$ 表示稀疏度,则 $\mathbf{X}$ 中不为零系数的个数为 $K$ ,其余 $N-K$ 个系数则为零或者接近于零。

构造一个 $M \times N$  维的多项式确定性矩阵 $\Phi_B \in \Phi_0^{M \times N}$ ,同时对稀疏向量 $\mathbf{X}$ 进行有效采样以简便快速构造矩阵,取 $p=7, r=2$ ,根据文献[14],从 $\Phi_B$ 中随机挑选 $N'$ 列,构成的 $M \times N'$ 的多项式确定性矩阵 $\mathbf{Q}_1, \mathbf{Q}_1$ 满足 RIP 性质,其中, $P^{r+1} - (r+1)p^2 < N' < P^{r+1}$ 。由 2.2 节中的方法生成 $D=2$  的分块多项式确定性矩阵 $\Phi = \text{blockdiag}(\Phi_1, \Phi_1)$ 。

将稀疏向量 $\mathbf{X}$ 投影到生成的分块多项式确定性矩阵 $\Phi$ 上,即 $\mathbf{Y} = \Phi \mathbf{X}$ ,获得随机测量值 $\mathbf{Y}$ 。至此, $\Phi$ 关键点特征描述向量的维度由 288 维变为 49 维。

### 2.5 特征描述向量的配准

分别取模板图像和待配准图像的特征向量作为待比较的两个特征向量,并分别表示为 $\mathbf{U}_i = \{u_{i1}, u_{i2}, \dots, u_{iM}\}$  和 $\mathbf{V}_i = \{v_{i1}, v_{i2}, \dots, v_{iM}\}$ ,则随机两个关键点特征描述向量的欧氏距离为

$$d(\mathbf{U}_i, \mathbf{V}_i) = \sum_{m=1}^M |u_{im} - v_{im}| \quad (19)$$

可以获得模板图像关键点 $\mathbf{U}_i$ 与待匹配图像最近关键点 $\mathbf{V}_i$ 的距离 $d(\mathbf{U}_i, \mathbf{V}_i)$ ,以及 $\mathbf{U}_i$ 与待匹配图像次近关键点向量 $\mathbf{V}_p$ 的距离 $d(\mathbf{U}_i, \mathbf{V}_p)$ ,当 $d(\mathbf{U}_i, \mathbf{V}_i)/d(\mathbf{U}_i, \mathbf{V}_p)$ 小于指定的阈值时(根据文献[12]经验,一般取 0.6),则可认为 $\mathbf{U}_i$ 与 $\mathbf{V}_i$ 匹配。

### 3 仿真实验与性能分析

本文选择3种算法进行比较,分别是传统的SIFT算法(算法1)、基于确定性多项式的SIFT算法(算法2)和分块多项式确定性矩阵的SIFT算法(算法3)。算法实现编程环境为Matlab 2010a,其整个实验运行环境为64位Window10系统,CPU 1.8 GHz,Intel Core i3,内存4 GiB。

为便于说明,采用同一种设备获取的同模态图像。

实验1 将两幅同空间拍摄下的图像用3种算法进行配准,所使用图像如图2所示,结果如表1所示。

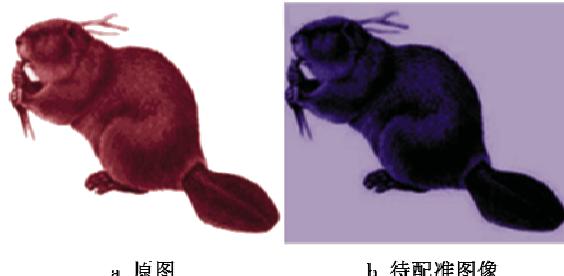


图2 原图和待配准图像(实验1)

Fig. 2 Original image and image to be registered (Experiment 1)

表1 各配准方法的性能参数比较(实验1)

Table 1 Performance parameters of each registration method (Experiment 1)

参数性能	算法1	算法2	算法3
配准精度/%	77.4	92.7	93.1
配准时间/s	0.126	0.093	0.085

实验结果表明算法3在配准精度和配准时间上皆优于另外两种算法。

实验2 将两幅不同空间拍摄的同模态图像进行配准,所使用图像如图3所示,结果如表2所示。



图3 原图和待配准图像(实验2)

Fig. 3 Original image and image to be registered (Experiment 2)

表2表明,算法3在对不同空间拍摄的图像配准时,性能优于其他两种算法,配准时间花费最少。

对3种算法的配准后图像与参考图像的均差和进

行对比,如图4所示。

表2 各配准方法的性能参数比较(实验2)

Table 2 Performance parameters of each registration method (Experiment 2)

参数性能	算法1	算法2	算法3
配准精度/%	73.4	89.8	90.2
配准时间/s	0.115	0.105	0.095

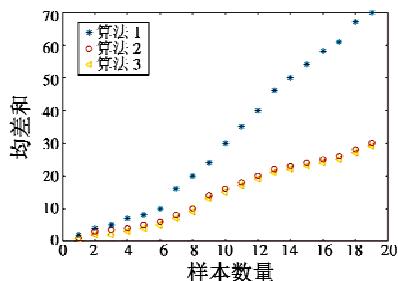


图4 3种配准算法的差值图像均差和

Fig. 4 Sum of mean deviation of three registration algorithms

通过对3种算法的配准后图像与参考图像的配准精度、配准时间以及差值图像均值对比可以看出:传统的SIFT算法的性能最差,基于多项式确定性矩阵的SIFT算法较传统的SIFT算法有明显的改善,分块多项式确定性矩阵SIFT图像配准算法在各项指标上有着较好的提升。

### 4 总结

结合稀疏投影理论,提出了分块多项式确定性矩阵的SIFT算法<sup>[19]</sup>,该算法将图像的关键点领域像素梯度方向由传统的8个增加到18个,并利用分块多项式确定性矩阵对描述子进行降维,对降维后的描述子向量进行配准。梯度方向的增加有利于特征的提取,而对描述子向量的降维有利于提高配准的速度。实验结果表明,本文在配准精度和配准时间上,与其他算法相比都有较好的改善。

### 参 考 文 献

- [1] LOWE D G. Objection recognition from local scale-invariant feature [C]//Proceeding of the Seventh IEEE International Conference on Computer Vision, 1999:1150-1157.
- [2] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2):91-110.
- [3] MASHMOUD H, MASULLI F, ROVETTA S. Feature-based medical image registration using a fuzzy clustering segmentation approach[C]//The 9th International Meeting Computational Intelligence Methods for Bioinformatics and Biostatistics, 2012:7845-7857.

- [4] WEI L F, PAN L, LIN L, et al. The retinal image registration based on scale invariant feature [C]//The 3rd International Conference on Biomedical Engineering and Informatics (BMEI), IEEE, 2010:639-643.
- [5] 赵启兵,王养柱,胡永浩. 基于改进 SIFT 算法的无人机遥感影像匹配[J]. 电光与控制,2012,19(3):36-39.
- [6] 胡文超,周伟,关键. 基于改进 SIFT 的遥感图像匹配方法[J]. 电光与控制,2017,24(5):36-39.
- [7] CANDES E J, ROMBERG J, TAO T. Robust uncertainty principle: exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions on Information Theory, 2006, 52(2):489-509.
- [8] DUARTE M F, DAVENPORT M A, TAKHAR D, et al. Single-pixel imaging via compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2):83-91.
- [9] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4):1289-1306.
- [10] XU Z J, DAI H L, CAO P P. Processing of sonar image based on compressive sensing[J]. Advanced Material Research, 2011(301-303):719-723.
- [11] HAN B, WU F, WU D P. Image representation by compressive sensing for visual sensor networks[J]. Advanced Material Communication and Image Representation, 2010, 21(4):325-333.
- [12] 杨飒,夏明华,郑志硕. 基于多项式确定性矩阵的 SIFT 医学图像配准算法[J]. 激光与光电子学进展, 2016(8):122-128.
- [13] 杨飒,郑志硕. 基于稀疏随机投影的 SIFT 医学图像配准算法[J]. 量子电子学报,2015,32(3):283-289.
- [14] LI S F, WEI S S, JIN L B, et al. Research on measurement matrix based on compressed sensing theory [C]//The 3rd IEEE International Conference on Control Science and Systems Engineering, 2017:716-719.
- [15] GUAN X, GAO Y, CHANG J, et al. Advances in theory of compressive sensing and applications in communication [C]//The 1st International Conference on Instrumentation, 2012:662-665.
- [16] HAUPT J, BAJWA W H, RAZ G, et al. Toeplitz compressed sensing matrices with applications to sparse channel estimation[J]. IEEE Transactions on Information Theory, 2010, 56(11):5862-5875.
- [17] QIU W, ZHOU J X, ZHAO H, et al. Three-dimensional sparse turntable microwave imaging based on compressive sensing[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(4):826-830.
- [18] PAGANELLI C, PERONI M, RIBOLDI M, et al. Scale invariant feature transform in adaptive radiation therapy: a tool for deformable image registration assessment and re-planning indication[J]. Physics in Medicine & Biology, 2013, 58(2):287.
- [19] 王永明,王贵锦. 图像局部不变性特征与描述[M]. 北京:国防工业出版社,2010.

(上接第 11 页)

- 局运动估算方法[J]. 航空学报,2006,27(1):94-97.
- [3] 徐瑞,王睿,李怡,等. 动态场景下基于 Bayesian 分类光流法的运动目标检测[C]//中国仪器仪表学会第十三届青年学术会议论文集. 北京:中国仪器仪表学会, 2011:66-70.
- [4] 盛安,董楠,张波,等. 面向电子稳像应用的模糊聚类运动估计算法研究[J]. 计算机应用研究,2015,32(2):598-602.
- [5] 聂烜,吴成富,陈怀民. 一种基于奇异点检测的光流场去噪方法[J]. 计算机工程,2009,35(5):207-208,220.
- [6] 屠大维,江济良. 改进的光流运动图像分析方法及其应用[J]. 光学精密工程,2011,19(5):1159-1164.
- [7] RUBLEE E, RABAUD V, KONOLIGE K, et al. ORB: an efficient alternative to SIFT or SURF[C]//IEEE International Conference on Computer Vision (ICCV), 2011:

2564-2571.

- [8] BOUGUET J Y. Pyramidal implementation of the Lucas-Kanade feature tracker description of the algorithm[J]. OpenCV Documents, 1999, 22(2):363-381.
- [9] KALAL Z, MIKOLAJCZYK K, MATAS J. Forward-backward error: automatic detection of tracking failures[C]// IEEE Computer Society, International Conference on Pattern Recognition, 2010:2756-2759.
- [10] 王智军,王建华. 基于 SIFT 验证的 Mean Shift 跟踪运动目标新算法[J]. 电光与控制,2016,23(11):93-96.
- [11] COMANICIU D, RAMESH V, MEER P. Real-time tracking of non-rigid objects using Mean Shift [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2002:2142-2149.
- [12] 胡威. 基于 Meanshift 的视频人体目标跟踪算法研究[D]. 上海:上海交通大学,2013.