

文章编号:1001-9014(2011)01-0021-06

基于多尺度特征提取的运动目标定位研究

孔军^{1,2,3}, 汤心溢¹, 蒋敏²

(1. 中国科学院上海技术物理研究所, 上海 200083; 2. 江南大学物联网工程学院, 江苏 无锡 214122;
3. 中国科学院研究生院, 北京 100039)

摘要:从尺度不变特征变换算法的实时性与鲁棒性分析入手, 针对其在特征点匹配精度和匹配效率两方面不足, 提出一种基于运动目标的多尺度特征提取算法. 该算法通过设计出一种基于尺度因子变化的高斯核模板尺寸自适应调整以及时间轴帧图像双向配准的办法, 成功地修正了运动目标图像配准的实时性与鲁棒性的不足. 实验证明, 多尺度特征提取算法能够有效而快速地完成时间轴帧图像的特征点匹配.

关键词:尺度不变特征变换; 多尺度; 尺度因子; 帧图像

中图分类号:TP391.41 **文献标识码:**A

Object location technique for moving target based on multi-scale feature extraction

KONG Jun^{1,2,3}, TANG Xin-Yi¹, JIANG Min²

(1. Shanghai Institute of Technical Physics, Chinese Academy of Science, Shanghai 200083, China;
2. School of Internet of Things and Sensor Network Engineering, Jiangnan University, Wuxi 214122, China;
3. Graduate School of Chinese Academy of Science, Beijing 100039, China)

Abstract: Beginning with the analysis of the real-time performance and robustness of scale-invariant feature transform (SIFT), the paper optimized traditional algorithm in both aspects of matching time and accuracy. A multi-scale feature extraction algorithm was proposed which is based on moving target. This algorithm was devised in two improved ways. One way was that the size of the template could automatically adjust along with the change of the scale factor. The other was that a bidirectional feature points matching was introduced into the algorithm. With the improved algorithm, the weakness of the real-time performance and robustness was amended successfully for match between the images and the moving target. Finally, experiment showed that with the improved algorithm, the sequential frame images based on time-axis could be matched quickly and accurately.

Key words: scale-invariant feature transform (SIFT); multi-scale; scale factor; sequential frame images

PACS: 07.05.Pj

引言

随着对无人机自主化研究不断深入, 基于运动目标机器视觉的课题已经在各个国家展开, 其主要研究方向集中在“目标识别”、“目标定位”和“目标跟踪”三个方面, 而视觉图像的特征提取或图像配准是这三个方面的前提和基础.

主元分析法^[1,2] (PCA) 和独立分析法^[3] (ICA) 的提出之初用于对静态图像的纹理和细节处理, 对于运动目标的特征提取存在实时性不足、精确度不

高、鲁棒性较差等缺点; 引入了具有大小、旋转和平移三不变性的区域描述算子的不变矩法^[4], 虽增强了图像抗旋转、缩放等鲁棒性, 但易受到光照、仿射和遮挡等因素的制约, 且对差别较小或噪声干扰过大的不封闭结构的特征提取能力不强, 实时性问题依然存在; David G. Lowe 在文献^[5,6]中指出: 在现有的局部不变量的描述子中, 尺度不变特征变换 (Scale-Invariant Feature Transform, 简称 SIFT) 描述子性能最优, 其特征向量包含丰富的图像内容信息, 提取的图像特征对图像旋转、尺度缩放等具有不变

收稿日期: 2010-06-21, 修回日期: 2010-12-18

Received date: 2010-06-21, revised date: 2010-12-18

基金项目: 国家自然科学基金多年期重大国际合作研究项目(60910005)及国家自然科学基金资助项目(60805014)

作者简介: 孔军(1974-), 男, 安徽合肥人, 中国科学院上海技术物理研究所博士生, 主要从事机器视觉和目标跟踪方面的研究, E-mail: j-kong@163.com.

性,对仿射变换、噪声、光照也保持较好的稳定性, SIFT 算法虽然在实时性上有了提升,但依然不能满足无人机等视觉主体对运动目标跟踪的实时性要求,并且算法的匹配阈值对其精度的制约影响了算法本身的鲁棒性.

根据上面的分析,可以得出这样的结论:对于运动目标图像的特征点匹配技术是一门不断发展的识别技术,还没有获得大家一致公认的算法,离实用性转化还有着不小的距离. 本文从 SIFT 的鲁棒性与实时性分析入手,对算法的特征点匹配精度和匹配效率两方面进行优化,提出一种基于运动目标的多尺度特征提取算法 (Multi-Scale Feature Extraction, 简称 MSFE), 实验证明,多尺度特征提取算法能够有效而快速的完成时间轴帧图像的特征点匹配.

1 多尺度特征提取算法

针对时间轴连续帧图像会发生旋转、缩放、亮度等变化特点,多尺度特征提取算法首先构建图像的多尺度空间,然后获取和优化特征点,并在此基础上提取出具有位置、尺度、旋转等不变量的局部特征描述子.

1.1 多尺度空间的构建

设原始图像为 $I(x, y)$, 高斯滤波函数为 $G(x, y, \sigma)$, 利用高斯滤波函数对原始图像进行模糊化处理得到一幅相对应的二维图像的尺度空间 $L(x, y, \sigma)$, 见公式(1), 其中 σ 表示尺度因子.

$$L(x, y) = G(x, y, \sigma) * I(x, y) \\ = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} * I(x, y) \quad (1)$$

为了有效地在尺度空间中检测到稳定的极值点, 研究中提出了高斯滤波差分计算 (Difference of Gaussian, 简称 DOG), 其本质是归一化 LOG (Laplacian of Gaussian) 算子的简单近似^[7], 见公式(2).

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

传统的 SIFT 算法本身复杂度较高、参数较多、计算费时, 最佳参数往往不能统一确定, 这给图像配准工作带来额外的工作成本. 通过图像配准实验, 统计出 SIFT 算法各个阶段的时耗的百分比, 其中的多尺度空间构建环节耗时占据了算法执行总时间的 35% 到 60%, 具体算法如下:

第 1 步: 根据公式(1), 利用高斯卷积核 $\sigma \cdot 2^{n/s}$ 对原始图像进行模糊化处理, 生成 $s+3$ 层高斯金字塔图像, 得到第一组 (octave) 高斯金字塔图像 (或称

高斯多尺度空间), 其中 $n=0, 1, 2 \dots s+2$, s 为该组的尺度空间的子层数, 为了获得具有一定重复性且稳定性较好的极值点, 本研究将子层数设定为 3.

第 2 步: 以后各组的高斯金字塔图像的首幅图像是由前一组的首幅图像经过下采样 (up-sampling) 得到^[8], 并重复类似 step1 的步骤, 形成该组的高斯金字塔图像.

第 3 步: 根据公式(2)对每组的高斯金字塔图像中相邻图像进行相减, 得到该组的高斯差分金字塔图像.

多尺度空间的构建是一个高斯金字塔图像和高斯差分金字塔图像的生成的过程^[9], 高斯金字塔图像的卷积运算时间要远远大于高斯差分金字塔图像的代数差运算时间, 并且卷积时间随着高斯卷积核尺寸和尺度因子增大而增大. 同时, 数字图像的平滑程度也直接受制于高斯卷积核尺寸和尺度因子的大小, 理论上, 高斯卷积核尺寸和尺度因子的值越大, 数字图像的平滑处理效果越好, 这点从算法“第 1 步”也能看出. 但是, 当高斯卷积核尺寸增大到一定程度, 特征点数目值开始出现临界, 随后该值开始出现下跌, 实验中统计, 随着卷积核尺寸由 $3 \times 3, 4 \times 4, \dots, 11 \times 11, 12 \times 12, 13 \times 13 \dots 20 \times 20 \dots$ 递增时, 特征点数目值的拐点大都出现在 $11 \times 11, 12 \times 12, 13 \times 13$. 传统算法是采用“固定且数值较大的高斯核尺寸”的方法来构建多尺度空间的. 若尺寸过小, 虽然省时, 但平滑程度低, 提取的特征点少; 若尺寸过大, 虽然平滑程度高, 但费时, 提取的特征点也未必多. 针对这一矛盾, 本文在 MSFE 算法中设计出一种基于尺度因子变化的高斯核模板尺寸自适应调整的办法对多尺度空间做自适应重构, 以解决传统算法中高斯滤波器核尺寸一成不变的缺陷, 保证其随着尺度因子变化时做出自动且最佳的配置. 实验根据以下公式配置高斯核尺寸 $[x, y]$:

$$\begin{cases} x = y = 10 & \text{高斯卷积核尺寸} \leq 12 \\ x = y = 12 & \text{高斯卷积核尺寸} > 12 \end{cases} \quad (3)$$

公式(3)表明, 随着高斯卷积核尺寸不断递增且没超过 $[12 \times 12]$, 我们就以 $[10 \times 10]$ 作为卷积核模板, 否则采用 $[12 \times 12]$.

1.2 多尺度空间极值点的检测和关键点的精确定位

在高斯差分金字塔图像中, 去除最底层和最上层图像, 在剩余的每一幅图像中求取不同尺度上的候选极值点, 即将这些图像中的每个点与同尺度图像的 8 个点以及上下相邻尺度图像的 18 个点进行比较, 如图 1 所示, 图中黑色实心圆点与 26 个空心




图1 DOG 尺度空间局部极值检测
Fig.1 Local extremum value of DOG scale space

圆点比较,如果黑色实心圆点的灰度大于或者小于其它 26 个像素,那么该黑色实心圆点就是极值点。

通过上述方法计算出来的极值点构成了初筛的图像特征点集合,但这些初筛的特征点由于存在较大的不稳定性,所以有的文献把它们称为关键点(key points)而非严格意义上的特征点,这些关键点往往加大了图像配准时出现的误配风险。

在关键点处用泰勒级数展开^[10],取前三项得:

$$D(X) = D + \frac{\partial D^T}{\partial X} X + \frac{1}{2} X^T \frac{\partial^2 D}{\partial X^2} X \quad (4)$$

公式(4)中, $X = (x, y, \sigma)^T$ 为关键点的偏移量, D 是 $D(x, y, \sigma)$ 在关键点处的值。令 $\frac{\partial D(X)}{\partial X} = 0$, 可得 X 的极值 X_{\max} :

$$X_{\max} = - \frac{\partial^2 D^{-1}}{\partial X^2} \frac{\partial D}{\partial X} \quad (5)$$

公式(5)代入式(4),并取前两项,可得公式(6)

$$D(X_{\max}) = D + \frac{1}{2} \frac{\partial D^T}{\partial X} X_{\max} \quad (6)$$

若 $|D(X_{\max})| \geq 0.03$, 该关键点保留为特征点,否则,丢弃。

由于公式(2)计算出高斯差分金字塔图像具有较强的边缘响应,所以定义不好的高斯差分算子的极值在横跨边缘处主曲率较大,在垂直边缘处主曲率较小,主曲率可以由 2×2 的 Hessian 矩阵 H 求出,见公式(7),其中 D 通过相邻采样点的差值计算出。

$$H = \begin{vmatrix} D_{xx} & D_{xy} \\ D_{xy} & D_{yy} \end{vmatrix} \quad (7)$$

由于 D 的主曲率和 H 的特征值成正比,令 H 特征值的最大和最小值分别为 α 和 β , 则:

$$\text{Tr}(H) = D_{xx} + D_{yy} = \alpha + \beta \quad (8)$$

$$\text{Det}(H) = D_{xx} D_{yy} - (D_{xy})^2 = \alpha\beta \quad (9)$$

令 $\gamma = \alpha/\beta$, 则:

$$\frac{\text{Tr}(H)^2}{\text{Det}(H)} = \frac{(\alpha + \beta)^2}{\alpha\beta} = \frac{(\gamma\beta + \beta)^2}{\gamma\beta^2} = \frac{(\gamma + 1)^2}{\gamma} \quad (10)$$

当 $r = 1$ 时, $\frac{\text{Tr}(H)}{\text{Det}(H)}$ 达到最小,并随着 r 值增加而增大,所以为了检测主曲率是否在某阈值 r 下,只需判断不等式(11)是否成立:

$$\frac{\text{Tr}(H)^2}{\text{Det}(H)} < \frac{(r + 1)^2}{r} \quad (11)$$

本文选取 r 经验值为 10。

这样通过拟合三维二次函数来确定特征点的位置和尺度,同时去除低对比度的关键点和不稳定的边缘点,提高了抗噪能力,增强了匹配鲁棒性。

1.3 确定特征点的梯度矢量

利用特征点邻域像素的梯度方向分布特性为每个特征点指定方向参数,使算子具有旋转不变性。

梯度模值:

$$m(x, y) = \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (12)$$

梯度方向:

$$\theta(x, y) = \arctan \frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \quad (13)$$

公式(12)和(13)分别表示高斯差分金字塔图像中在点 (x, y) 处的梯度大小和方向, $L(x, y)$ 为每个特征点所在的尺度。在以特征点为中心的邻域窗口 (16×16 像素窗口) 内采样,利用高斯函数对窗口内各像素的梯度大小进行加权,用直方图统计邻域像素的梯度方向。直方的主峰值(最大峰值)代表特征点邻域梯度的主方向,也就是特征点的主方向,这样图像中所标定出来的特征点将有 3 个信息量:位置、所处尺度大小和方向。

1.4 特征描述子生成

以每个特征点为中心取 16×16 的邻域作为采样窗口,将采样点与特征点的相对位置通过高斯加权后归入包含 8 个方向的直方图,最后得到 $4 \times 4 \times 8 = 128$ 维特征向量,形成尺度不变特征描述子。在构造特征描述子时,预先将特征点周围局部区域顺时针旋转至水平,并对此 128 维向量进行归一化处理,这样得到的特征描述算子具有旋转和尺度不变性,同时增强了其抗光照变化的鲁棒性。

1.5 特征点的双向匹配

两幅时间轴帧图像的特征描述子生成后,可以采用多维空间向量的欧式距离作为匹配强度准则,也就是计算出其中一幅图特征点集中每个特征点到另一幅图特征点集中所有特征点的欧氏距离作为两

幅图像中特征点的相似性判定度量,见公式(14).

$$d = \sqrt{\sum_{i=1}^{128} (x_{i1} - x_{i2})^2} \quad (i = 1, 2, \dots, 128) \quad (14)$$

其中 x_{i1} 表示第一幅图像上的某个点的特征描述子的第 i 维元素值, x_{i2} 表示第二幅图像上的某个点的特征描述子的第 i 维元素值.

传统算法是:取其中一幅图的某个特征点,并找出其与另一幅图中欧式距离最近的前两个特征点,在这两个特征点中,如果最近的距离除以次近距离小于某个匹配阈值,则接受这一对匹配点.该算法在具体实现时,特征点匹配存在较大错配率,虽然通过降低匹配阈值来减少错配率,但特征点数目减少,甚至在匹配阈值过低时(例如小于 0.2),会出现零匹配.如果我们把在图 A 特征点集中每个特征点寻找出图 B 特征点集中与之欧式距离最近点过程,称之为“正向配准”,那么在图 B 特征点集中每个特征点寻找出图 A 特征点集中与之欧式距离最近点过程^[11,12],称之为“反向配准”,而传统算法只完成单向配准,以至于算法的精度得不到提升,改进后多尺度特征提取算法如下:

第 1 步:建立极线约束条件,减少图像配准时搜索范围;

第 2 步:求出图 A 中某一个特征点 F_1 与图 B 中在对应极线上所有特征点的欧式距离,搜索出最近点 F_2 ,如果该欧式距离小于匹配阈值,保留 F_2 ,跳入第 3 步.否则,删除 F_1 ,重复第 2 步;

第 3 步:求出图 B 中 F_2 与图 A 中对应极线上所有特征点的欧式距离,搜索出最近点 F_3 ;

第 4 步:判断 F_1 和 F_3 是否相等,若是,匹配成功,否则,跳入第 2 步;

2 实验结果与分析

为验证文中算法的有效性,事先利用 HIROBO Shuttle SCEADU Evolution 50 型无人机自带的单目摄像机采集某道口车流状况视频图像序列,图像分辨率为 930×1360 ,帧率为 25 帧/秒,车辆平均速度 30km/h,然后按照时间间隔为 0.32 秒(间隔 8 帧)提取两幅时间轴的帧图像,以此作为算法检验的源图像.运行机器: Intel Core 2 Duo E4700 2.6GHz PC,内存 2GB,操作系统 Win XP,开发平台 VC++6.0.

2.1 利用传统 SIFT 算法的实验结果

通过传统 SIFT 算法,计算出两幅时间轴帧图像的特征点个数,前帧视图有 488 个,后帧视图有 489 个.图 2 中箭头的起点代表特征点位置、箭头方向代




图 2 时间轴帧图像特征点的梯度矢量

Fig. 2 Gradient of feature points in sequential frame image based on time-axis




图 3 SIFT 算法匹配结果(匹配阈值 = 0.15)

Fig. 3 Result of SIFT matching algorithm (threshold = 0.15)




图 4 SIFT 算法匹配结果(匹配阈值 = 0.3)

Fig. 4 Result of SIFT matching algorithm (threshold = 0.3)

表特征点所处邻域的主梯度方向、箭头长度代表梯度大小.

然后分别以匹配阈值 threshold = 0.15、threshold = 0.3 和 threshold = 0.6 对时间轴帧图像进行配准,如图 3、图 4 和图 5 所示,运行结果如表 1:

表 1 不同阈值下利用 SIFT 算法的匹配情况

Table 1 Result of matching based on different threshold by the use of SIFT algorithm

| 匹配阈值 | 前、后帧图像获得特征点数(个) | 匹配成功对数(对) | 匹配完成时间(秒) |
|------|-----------------|-----------|-----------|
| 0.15 | 488、489 | 0 | 8.82504 |
| 0.3 | 488、489 | 31 | 8.82550 |
| 0.6 | 488、489 | 121 | 8.82868 |

上述可分析得:(1)时间轴帧图像的特征点个




图 5 SIFT 算法匹配结果(匹配阈值 = 0.6)
Fig. 5 Result of SIFT matching algorithm (threshold = 0.6)

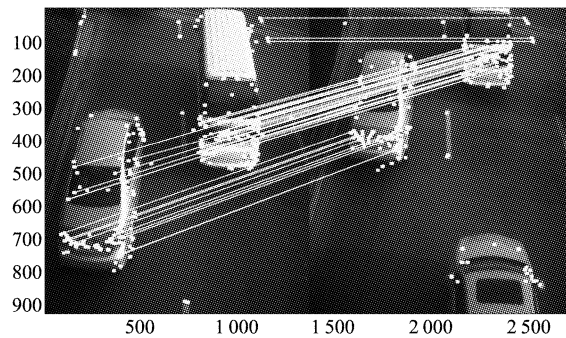


图 7 MSFE 算法匹配结果(匹配阈值 = 0.15)
Fig. 7 Result of MSFE matching algorithm (threshold = 0.15)

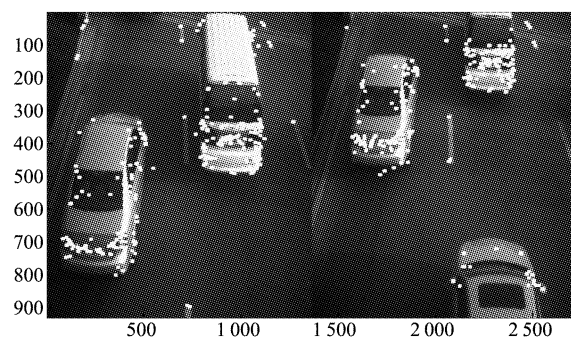


图 6 时间轴帧图像特征点
Fig. 6 Feature points in sequential frame image based on time-axis




图 8 MSFE 算法匹配结果(匹配阈值 = 0.3)
Fig. 8 Result of MSFE matching algorithm (threshold = 0.3)

数与匹配阈值无关,分别为 488 和 489 个;(2)当阈值小于某个值时(本实例小于 0.15),前、后帧不能完成正常配准,出现零匹配,见图 3;(3)匹配阈值增大,匹配成功对数增大,但错配率也增大.图 4 匹配成功对数为 31 对,错配 3 对,图 5 匹配成功对数为 121 对,错配 7 对;(3)无论匹配阈值多大,整个算法都耗时在 8.82s 左右,表明算法实时性不强,不利于无人机等视觉主体对移动目标的实时跟踪.

2.2 利用改进后 MSFE 算法的实验结果

通过改进后的 MSFE 算法,计算两幅时间轴帧图像的特征点个数,前帧视图有 270 个,后帧视图有 252 个,在图 6 中已标出.

然后分别以匹配阈值 $\text{threshold} = 0.15$ 、 $\text{threshold} = 0.3$ 和 $\text{threshold} = 0.6$ 对时间轴连续帧图像进行配准,如图 7、图 8 和图 9 所示,运行结果如表 2:

表 2 不同阈值下利用 MSFE 算法的匹配情况
Table 2 Result of matching based on different threshold by the use of MSFE algorithm

| 匹配阈值 | 前、后帧图像获得特征点数(个) | 匹配成功对数(对) | 匹配完成时间(秒) |
|------|-----------------|-----------|-----------|
| 0.15 | 270、252 | 48 | 5.41932 |
| 0.3 | 270、252 | 84 | 5.42782 |
| 0.6 | 270、252 | 108 | 5.41382 |




图 9 MSFE 算法匹配结果(匹配阈值 = 0.6)
Fig. 9 Result of MSFE matching algorithm (threshold = 0.6)

从改进后的多尺度特征提取算法实验结果得:(1)克服了传统算法在阈值较低情况下出现零匹配现象;(2)由于采用双向配准办法,改进后算法错配率同比传统算法低的多;(3)改进后的算法耗时大约在 5.42s 左右,算法实时性得到提高.

2.3 SIFT 和 MSFE 匹配精度比较

算法的鲁棒性可由匹配率^[13](matching rate,简称 MR)和错配率(false acceptance rate,简称 FAR)来衡量.匹配率表示两幅连续帧图像特征点正确匹配对数与两幅连续帧图像特征点个数最小值的比,




图 10 匹配阈值与匹配率关系曲线
Fig. 10 Curve of the threshold and MR




图 11 匹配阈值与错配率关系曲线
Fig. 11 Curve of the threshold and FAR

错配率表示两幅连续帧图像特征点错误匹配对数与两幅连续帧图像特征点个数最小值的比。图 10 表示两种算法的匹配阈值与匹配率关系,图 11 表示两种算法的匹配阈值与错配率关系。

由图 10 和图 11 可分析:(1)多尺度特征提取算法在相同阈值条件下匹配率要比传统的尺度不变特征变换法要高;(2)多尺度特征提取算法在相同阈值条件下对错配的抑制能力要比传统的尺度不变特征变换法强,在阈值较大情况下尤为突出。

4 结论

本文从 SIFT 的实时性与鲁棒性分析入手,对于其在特征点匹配效率和匹配精度两方面不足进行优化,提出一种基于运动目标的多尺度特征提取算法——MSFE。该算法通过设计出一种基于尺度因子变化的高斯核模板尺寸自适应调整以及时间轴帧图像双向配准的办法,成功地修正了运动目标图像配准的实时性与鲁棒性的不足。实验证明,多尺度特征

提取算法能够有效而快速的完成时间轴帧图像的特征点匹配,此研究在无人机等视觉主体对运动目标自主定位方面有着重要的应用前景。

REFERENCES

- [1] Aykut Ekinici M M. Human gait recognition based on kernel PCA using projections[J]. *Journal of Computer Science & Technology*, 2007(06): 867—876.
- [2] Aykut Ekinici M M. Palmprint recognition by applying wavelet-based kernel PCA[J]. *Journal of Computer Science & Technology*, 2008(05): 851—861.
- [3] Gotman J. Automatic removal of eye movement artifacts from the EEG using ICA and the dipole model[J]. *Progress in Natural Science*, 2009(09): 1165—1170.
- [4] Hu M K. Visual pattern recognition by moment invariants [J]. *IRE Trans Inf Theory*, 1962(8): 179—187.
- [5] Lowe David G. Object recognition from Local scale-invariant features[J]. *International Conference on Computer Vision*, Corfu, September, 1999, 3(1): 1150—1157.
- [6] Lowe David G. Distinctive image features from scale-invariant keypoints[J]. *International Journal of Computer Vision*. 2004, 60(2): 91—110.
- [7] YI Cheng-Tao, WANG Xiao-Tong, XU Xiao-Gang. Research on algorithm of IBM based on SIFT[J]. *Microelectronics & Computer* (易成涛,王孝通,徐晓刚.基于 SIFT 的图像建模算法研究. *微电子学与计算机*), 2009, 26(12): 1—3.
- [8] PIAN Zhao-Yu, MENG Xiang-Ping, SHU Ying-Li. Automatic identification of salient object based on multi-features images[J]. *J. Infrared Millim. Waves* (片兆宇,孟祥萍,舒英利.基于多特征图像显著目标的自动识别. *红外与毫米波学报*), 2009, 28(4): 293—297.
- [9] LI Fang-Fang, XIAO Ben-Lin, JIA Yong-Hong, et al. Improved SIFT application in automatic registration of remotely-sensed imagery[J]. *Geomatics and Information Science of Wuhan University* (李芳芳,肖本林,贾永红,等. SIFT 算法优化及其用于遥感影像自动配准. *武汉大学学报·信息科学版*), 2009, 34(10): 1245—1249.
- [10] WANG Hong-Bing, PENG Zhen-Ming, LIU Jie, et al. Feature points detection and tracking based on SIFT combining with KLT method[J]. *Proc. SPIE*. 2009(7506): 75062N1—10.
- [11] LIU Huan-Min, WANG Hua, DUAN Hui-Fen. A bidirectional matching SIFT algorithm [J]. *Ordnance Industry Automation* (刘焕敏,王华,段慧芬.一种改进的 SIFT 双向匹配算法. *兵器自动化*) 2009, 28(6): 89—91.
- [12] ZHANG Jie-Yu, BAI Xiao-Jing, XU Li-Yan, et al. A method correcting SIFT mismatching based on spatial distribution descriptor [J]. *Journal of Image and Graphics* (张洁玉,白小晶,徐丽燕,等.基于空间分布描述符的 SIFT 误匹配校正方法. *中国图象图形学报*), 2009, 14(7): 1369—1377.
- [13] WANG Yun-Xin, WANG Da-Yong, LIU Tie-Gen, et al. Local SIFT analysis for hand vein pattern verification[J]. *Proc. SPIE*. 2009(7512): 751204 1—7.