

文章编号 1004-924X(2014)06-1613-09

基于字典描述向量的实时图像配准

王健博^{1,2}, 朱明^{1,3*}

- (1. 中国科学院 长春光学精密机械与物理研究所 中国科学院航空光学成像与测量重点实验室, 吉林 长春 130033;
2. 中国科学院大学, 北京 100039;
3. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033)

摘要:针对传统的特征向量计算方法复杂度高、耗时长、占用内存多等缺点,提出了一种基于字典描述向量的图像配准方法。该算法采用K-奇异值分解(K-SVD)方法生成字典,通过比较特征点临近区域图像与字典中基底图像的相似性得到特征描述向量,从而降低了描述向量的计算复杂度,提高了算法的实时性。实施该算法时,首先通过随机KD树算法对参考图像和待配准图像的特征点进行匹配,然后使用经典随机抽样一致性(RANSAC)算法剔除误匹配点对,最后应用最小二乘法对得到的匹配点对进行参数估计,从而得到两幅待配准图像的空间几何变换关系。实验表明结果,本文提出的描述向量计算方法降低了描述向量的存储空间,加快了特征匹配的速度,可在保证配准准确度的前提下实现配准过程。

关键词:字典;特征描述向量;图像配准;K-奇异值分解算法

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20142206.1613

Real time image registration based on dictionary feature descriptor

WANG Jian-bo^{1,2}, ZHU Ming^{1,3}

- (1. *Key Laboratory of Airborne Optical Imaging and Measurement, Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;*
 - 2. University of Chinese Academy of Sciences, Beijing 100039, China;*
 - 3. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)*
- * *Corresponding author, E-mail: zhu_mingca@163.com*

Abstract: As traditional description vector calculation method used in image registration is too complex, time consuming and taking up more memory, a novel dictionary based local feature description algorithm was proposed. The K-singular Value Decomposition (KSVD) method was used to generate dictionary and the feature descriptor was obtained by comparing the similarity between feature point region in images and elements in the dictionary. By above, the description vector generation algorithm was simplified and a higher feature matching speed was obtained. The matching process could be car-

收稿日期:2013-04-07;修订日期:2013-05-09.

基金项目:国家自然科学基金资助项目(No. 61172111)

ried out by using randomized KD(k -dimension) tree algorithm. Then, the Random Sample Consensus (RANSAC) was used to choose the correct matching pairs. Finally, the transform parameters were estimated by using the least square method and the space geometric transformation of two images to be registered was obtained. Results from experiments show that the proposed method reduces the description vector storage space, speeds up the feature matching and implements the registration process in real time.

Key words: dictionary; feature description vector; image registration; K-singular Value Decomposition (KSVD) method

1 引言

图像配准在遥感信息处理、医学影像分析及机器视觉等领域都得到了广泛应用^[1-5]。该项技术可解决传感器的物理特性差异或者拍摄时间、拍摄视角的不同所导致的对同一场景拍摄的图像所包含的空间信息无法相互对应的问题,从而为后续的图像拼接、图像融合等处理过程提供有效的数据源。因此,设计一种快速、高效的图像配准算法对提高实时图像处理系统的性能具有重要意义。

目前的图像配准方法根据处理对象的不同大致可以分为两类:基于灰度信息的图像配准方法和基于特征信息的图像配准方法。基于灰度信息的图像配准方法具有实现简单,计算速度快等优点,但配准效果容易受到图像中噪声、光照或者重叠区域大小的影响,这在一定程度上限制了该方法的应用范围;基于特征信息的图像配准方法是通过分析图像特征实现配准的,算法的运算复杂度低,不易受图像的灰度变化以及几何形变等因素的影响。

基于特征信息的图像配准方法由图像特征提取和特征匹配两部分内容组成。图像特征包含点特征、线特征和区域特征三种。在各种常见的特征匹配方法中,Lowe^[6]提出的尺度不变特征变换(Scale Invariance Feature Transform, SIFT)方法得到了国内外专家学者的广泛关注。祁燕等^[7]利用 SIFT 方法提取待配准图像特征点,采用马氏距离筛选特征点,从而减少了错误匹配点对的数目。SIFT 算法因为特征描述向量维数较高,在时间复杂度和空间复杂度方面无法满足实时性的要求,因此较少应用于实际工程项目。针对 SIFT 的缺点,Bay 等^[8]提出了加速鲁棒特征(Speed-up

Robust Feature, SURF)算法,该算法的计算速度优于 SIFT,其余性能与 SIFT 算法接近。张锐娟等^[9]使用 SURF 算法提取特征点并应用最近邻匹配策略进行图像配准,实验表明该方法取得了较好的效果。虽然和 SIFT 方法相比, SURF 方法的运算速度有所提高,但是由于特征描述向量的维数没有明显下降,算法的计算时间依然较长,仍然无法满足各种相关的图像处理装置对实时性的要求。

针对上述问题,本文提出一种基于字典描述向量的图像实时配准方法。该配准方法将 DOG 特征点提取方法所具有的抗旋转变换、尺度变化以及光照影响等特性与 DFD 描述符所具有的占用空间小、计算速度快等优势相结合,因此可以实时准确地完成特征提取与描述向量生成。在搜索同名特征点的过程中,通过对穷举搜索、传统的 KD 树算法及 BBF 算法在处理高维空间数据搜索时的优缺点进行比较分析,选取随机 KD 树算法用于加速该搜索过程,从而进一步提高了算法性能。

2 算法介绍

2.1 KSVD 字典学习算法

由于传统的冗余字典中的原子数目过多,直接采用传统方法对输入图像进行稀疏分解会导致算法的整体运行效率大大下降。采用 KSVD 算法的目的是为了减少字典中原子的数目,降低计算量。具体方法为:对于规模较大的训练图像集,定义训练图像矩阵为 $\mathbf{Y}=[y_1, \dots, y_p]$, 大小为 $n \times P$, n 为训练图像分块的长度, P 为训练图像分块的个数,对 y_i 的稀疏表示可以分解为以下的优化问题:

$$\min \left\{ \left\| y_i - \tilde{\mathbf{D}}\mathbf{a} \right\|_2^2 \right\} \text{ s. t. } \|\mathbf{a}\|_0 \leq T_0, \quad (1)$$

其中: $\tilde{\mathbf{D}}$ 为初始随机字典,大小为 $n \times K$, $P \gg K$,并且 $k > n$; \mathbf{a} 为稀疏分解系数; T_0 为稀疏度。首先考虑稀疏求解。假定字典 $\tilde{\mathbf{D}}$ 固定,则上述优化问题可以转换为求解稀疏分解系数 \mathbf{a} 。对于输入的训练图像可以表示为:

$$\min \left\| \mathbf{y}_i - \tilde{\mathbf{D}}\mathbf{a} \right\|_2^2 = \sum_{i=1}^M \left\| \mathbf{y}_i - \tilde{\mathbf{D}}\mathbf{a}_i \right\|_2^2,$$

其中: $\| \mathbf{a}_i \|_0 \leq T_0, i=1,2,\dots,M$ 。(2)

接下来需要考虑如何更新 $\tilde{\mathbf{D}}$ 以满足式(2),即最终所获得的字典,从而能够稀疏表示输入图像分块样本集。根据Elad等^[11]提出的KSVD算法,设 \mathbf{Y} 为输入样本集, $\tilde{\mathbf{D}}$ 为初始化随机字典, $\tilde{\mathbf{d}}_i$ 为 $\tilde{\mathbf{D}}$ 的第 i 列, \mathbf{a}_T^i 为 \mathbf{A} 的第 i 行,假定更新其第 k 个原子,在给定稀疏度 T_0 的情况下,由式(2)可以得出:

$$\begin{aligned} \left\| \mathbf{y}_i - \tilde{\mathbf{D}}\mathbf{A} \right\|_2^2 &= \left\| \mathbf{Y} - \sum_{j=1}^K \tilde{\mathbf{d}}_j \mathbf{a}_T^j \right\|_2^2 = \\ &= \left\| \left[\mathbf{Y} - \sum_{j \neq k} \tilde{\mathbf{d}}_j \mathbf{a}_T^j \right] - \tilde{\mathbf{d}}_k \mathbf{a}_T^k \right\|_2^2 = \\ &= \left\| \mathbf{E}_k - \tilde{\mathbf{d}}_k \mathbf{a}_T^k \right\|_2^2, \end{aligned} \quad (3)$$

式中: K 为字典 $\tilde{\mathbf{D}}$ 中原子数目的总和;将 $\{ \mathbf{y}_i \}$ 中使用 $\tilde{\mathbf{d}}_k$ 的图像分块记录在 ω_k 中,如公式(4)所示:

$$\omega_k = \{ i | 1 \leq i \leq K, \mathbf{a}_T^k(i) \neq 0 \}. \quad (4)$$

定义矩阵 $\mathbf{\Omega}_k$ 大小为 $P \times |\omega_k|$,其中: ω_k 位于 (i, i) 的值为1,其余值为0, $\mathbf{a}_R^k = \mathbf{a}_T^k \mathbf{\Omega}_k$, $\mathbf{E}_k^R = \mathbf{E}_k \mathbf{\Omega}_k$,由此可以得到:

$$\left\| \mathbf{E}_k \mathbf{\Omega}_k - \tilde{\mathbf{d}}_k \mathbf{a}_T^k \mathbf{\Omega}_k \right\|_F^2 = \left\| \mathbf{E}_k^R - \tilde{\mathbf{d}}_k \mathbf{a}_R^k \right\|_F^2. \quad (5)$$

对 \mathbf{E}_k^R 进行SVD分解,得到 $\mathbf{E}_k^R = \mathbf{U} \mathbf{\Delta} \mathbf{V}^T$,使用矩阵 \mathbf{U} 的第一列更新原子 $\tilde{\mathbf{d}}_k$,以此流程更新所有原子,最终可以得到本文所用的字典。

2.2 基于字典的描述向量计算

对于使用DOG^[6]检测得到的特征点,以该点为中心建立特征点区域图像FPRI,为了使各尺度对应的特征点FPRI具有较好的一致性,令FPRI的初始维度与检测得到的特征点的尺度相同,由于在计算高斯尺度空间前已将图像尺度扩大了一倍,因此FPRI的尺寸可以表示为:

$$\begin{aligned} \text{FPRI}_H &= 2 * \beta_H * 2^{(\omega-1)} \\ \text{FPRI}_W &= 2 * \beta_W * 2^{(\omega-1)}, \end{aligned} \quad (6)$$

其中: β_H, β_W 为所要计算的字典图像的宽和高; ω 为DOG方法找到的特征点所在的尺度;FPRI_H,

FPRI_W为特征点区域的宽和高。本文选取 $\beta_H = \beta_W = 24$ 。之后还需要对FPRI做双线性插值,将其尺度调整到与字典图像相同。图1给出了一组示例。从图1可以看到,尺度调整后的特征点区域图像与字典中的基底图像大小相同,这可以使描述向量的计算更加方便。为了使所建立的字典包含训练集的绝大部分信息,根据稀疏编码的原理,需要建立包含较大规模样本的样本集,故将得到的超过400 000幅FPRI图像作为KSVD算法的输入,如图2所示,生成100幅 24×24 基底图像的字典,表示为: $\beta = \beta_1, \dots, \beta_{100}$ 。




图1 原始FPRI图像及尺度调整后图像
Fig. 1 Original FPRI image and its rescaled image




图2 训练得到的基底图像集
Fig. 2 Basis image sets obtained from training dataset

为提高训练得到的字典对各种场景的适应性,训练集图像选取航空实拍视频截图的图像以及Google earth图像作为示例图像,如图3所示。

图3(a)为包含典型地形地貌的实际航拍视频,图像大小为 640×480 ,图3(b)、图3(c)和图3(d)均为Google earth中提取的典型航拍图像,图像大小均为 640×480 。

由于特征描述子是对图像局部结构特征的量化描述,故能够充分反映特征点附近局部图像的形状和纹理的结构特性,且图2字典中的 β_i 与样本图像的某一特性(边缘、梯度等)相关联,因此可

以通过比较 FPRI 与字典中基底 β_i 的相似程度得到特征点的描述向量 DFD 。

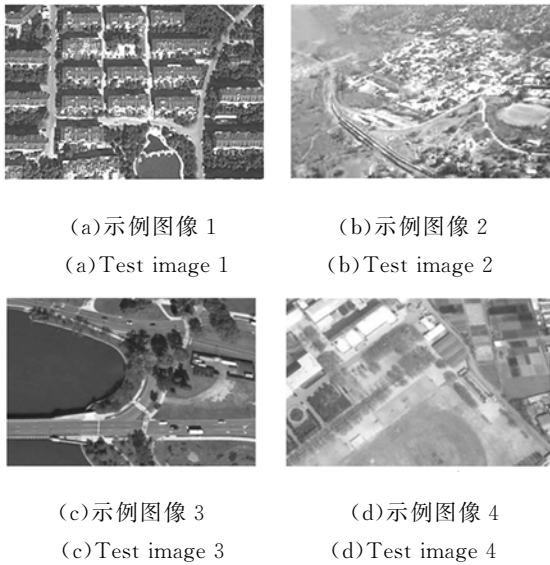


图 3 训练图像集中的示例图像
Fig. 3 Exmample images in training dataset

为得到 FPRI 与字典中元素 β_i 相似程度的比较结果,随机选取了一幅 FPRI 和一幅字典中的基底图像,分别如图 4(a)和图 4(b)所示。



图 4 提取出的 FPRI 与 β_i
Fig. 4 Extracted FPRI image and its β_i

显然,根据主观观测结果,图 4(a)中 FPRI 的右上角与图 4(b) β_i 的右上角相似程度较高,而图像块中其余部分的相似程度较低,如果仅是简单地比较两图像块的相似程度,则 FPRI 中相似程度最好的图像区域的空间信息可能会丢失。基于此,本文对该方法进行了改进,提出了一种基于区域重要性的图像块相似度比较方法,具体步骤为:首先将 FPRI 与 β_i 的对应像素相减,由于 FPRI 和 β_i 中像素的取值都为 $[0, 255]$,因此,相减之后得到的矩阵 \mathbf{P} 中元素的取值为 $[-255, +255]$, \mathbf{P} 中元素的值若为正,则代表了 β_i 中像素较 FPRI

中对应位置像素灰度值大,反之,则代表了 β_i 中像素较 FPRI 中对应位置像素灰度值小。若 \mathbf{P} 中元素值为零,则代表了 β_i 中像素与 FPRI 中对应位置像素灰度值相等。为计算方便,将 \mathbf{P} 中元素归一化,归一化后的值域为 $[-1, 1]$,将 \mathbf{P} 分为大小均等的 9 个区域,如图 5 所示。本文的 FPRI 为 24×24 的小块,因此每个区域均为 8×8 的图像块,对该区域求其极性:

$$\pi = \arg \max_{v \in \{-1, 0, 1\}} \left(\sum_{r=1}^8 \sum_{c=1}^8 v_{r,c} \right). \quad (7)$$

区域中像素的极性为:

$$v_{r,c} = \begin{cases} -1 & p_{r,c} < -e \\ 0 & -e < p_{r,c} < e \\ 1 & p_{r,c} > e \end{cases}, \quad (8)$$

其中: r, c 为区域中像素的索引; e 为判断像素极性的阈值。图 5 还给出了区域中 64 个像素对区域极性的投票结果,此过程产生了 9 个投票结果,且投票结果取值为 $\{-1, 0, 1\}$,投票结果组成的数组表征了 FPRI 与 β_i 的相似程度,生成的描述子所占用的空间为 $100 \text{ bit} \times 9 \text{ bit} \times 2 \text{ bit}$ 。




图 5 区域相似性计算
Fig. 5 Calculation of region similarity

由于区域投票有 3 种结果,因此无法采用 Euclidean 距离等距离测度计算描述子的相似程度。针对该问题,本文提出了一种类似汉明距离的描述矢量相似度度量方法。具体步骤为:如果 2 个描述子区域的投票具有相同的极性,例如 $(-1, -1), (0, 0), (1, 1)$,则可以认为它们的相似程度较高。这是因为它们对同一个给定区域给出了相同的匹配效果。如果匹配结果为 $(0, 1), (0, -1)$,由于极性为 0 表示待匹配的 FPRI 与 β_i 有部分区域相似,极性为 -1 或 1 同样表示待匹配的 FPRI 与 β_i 有部分区域相似,因此将待匹配 FPRI 视为可以接受的匹配。如果待匹配区域投票结果极性相反,例如 $(1, -1)$,则这 2 个区域匹配效果不好。因为极性相反表示了 2 个 FPRI 中仅有一

个与 β_i 匹配。对于描述子中的每一个单元,相似度度量结果为对应位非进位相减的和,该值越接近于零,表明 2 个单元的相似程度越高,而该值越高,则相似程度越低。2 个特征描述子的相似性度量为对应单元相似性度量的总和。

2.3 随机 KD 树算法

在提取到特征点并且计算出其相应描述向量后,还应找出由待匹配图像提取出的特征点集合中每一个待匹配点与另一幅待配准图像提取出的特征点集中距离最短的点。由于特征点描述符的维数较高,因此对同名特征点的搜索应具有较快的速度。传统的穷举搜索方法^[6]原理简单、易实现且效果较好,但由于未加入搜索策略,因此该方法效率相对较低;经典 KD 树算法在处理低维度数据时效果较好,但当检索高维度数据时,算法的时间复杂度和空间复杂度会迅速增大。尽管将 BBF 策略与经典 KD 树算法相结合可以较好地应对高维度数据搜索问题,但为了降低搜索耗时,该方法搜索到近似的特征点时会停止搜索,但这在一定程度上降低了特征点的匹配精度。

根据概率论与数理统计的基本原理,采用增加待搜索的数据节点数量的方式,可以增大检索到正确匹配特征点的概率。但是由于不存在独立的单一 KD 树节点,因此不满足联合概率分布的假设,所以无法通过增加 KD 树中搜索节点的方法解决问题。针对该问题,Silpa-Anan 等提出了随机 KD 树算法^[15],这种算法建立多个随机的 KD 树进行搜索,取代了单一的 KD 树的搜索方式。从而使任一搜索节点与其余搜索节点之间的相对独立性增加。Muja 等人^[16]通过大量实验比较了随机 KD 树与 BBF 在高维数据空间搜索的准确性和速度,结果证明随机 KD 树更适用于高维数据搜索。根据以上分析,本文采用随机 KD 树算法查找匹配点。

2.4 方法总结

图 6 是本文算法的流程图,首先利用实拍视频与 Google earth 数据库生成所需字典,然后用 DOG 算法提取参考图像和待配准图像中的特征点,采用本文提出的 DFD 算法生成特征点的描述向量,利用随机 KD 树算法找到特征点的最近邻初始匹配点对,通过 RANSAC 方法去除外点,最后应用最小二乘法对得到的匹配点对进行参数估计,从而得到两幅待配准图像的空间几何变换关系。

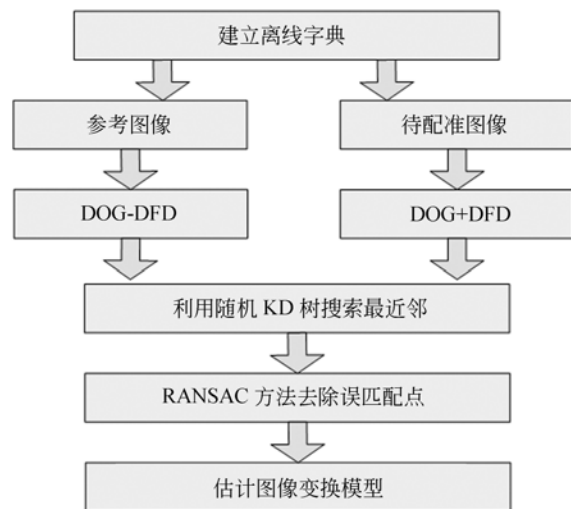


图 6 本文方法的流程图

Fig. 6 Flowchart of the proposed method

3 实验与结果分析

为了进一步验证所提算法的性能,实验中将本文的方法与传统方法进行了比较。实验中所采用的计算硬件配置如下:CPU 为 Intel core i3, 2.39GHz,内存为 2G。算法开发工具为 Matlab R2012a。

分别采用传统的 SURF 算法、SIFT 算法和本文方法对图 7 中的测试图像进行特征点提取与描述向量计算,测试图像为实拍图像。这里令 DFD 生成的字典为 100 维,则 DFD 描述向量占用的存储空间仅为 1 800 bits,相比 SURF 描述向量的 8 192 bytes,节约了 97.3%。其中:图 7(a)是 1 幅大小为 512×512 的航拍城镇图像,图 7(b)是 1 幅大小为 350×405 的航拍山地图像,实验中反复检测了 100 次,表 1 为特征点检测和描述子计算时间的统计结果。



(a) 测试图像 1

(b) 测试图像 2

(a) Test image 1

(b) Test image 2

图 7 测试图像

Fig. 7 Test images

由表 1 中给出的结果可以看到,本文提出的 DFD 算法在计算描述向量方面所耗费的时间要远远小于 SURF 和 SIFT 算法。DFD 算法的计算时间大概仅为 SIFT 描述向量的 2%。这是因

为在计算 DFD 描述向量过程中采用了基于字典的方法,仅需比较特征点邻域图像分块与字典中基底图像的相似性,这比采用梯度直方图统计的 SIFT 和 SURF 算法的计算复杂度更低。


表 1 采用 SURF、SIFT 以及本文方法提取特征点和计算描述向量的计算时间比较

Tab.1 Comparison of time cost for feature point extraction and description vector calculation by SIFT , SURF and the proposed method (s)

特征点数目	DOG 特征点检测时间	SURF 描述向量计算时间	DFD 描述向量计算时间	SIFT 描述向量计算时间
Fig. 7(a)	1 385	2.176	5.091	0.056
Fig. 7(b)	676	1.057	2.423	0.027

配准的准确率也是评价算法性能的一个重要指标。为了验证本文方法的配准准确率,先提取图 8 中测试图像的特征点,再计算相应的特征描述向量,并统计特征点匹配的正确率及匹配过程中所耗费的时间。由于采用了随机抽样一致(RANSAC)剔除了匹配过程中产生的外点,但为了更好地比较本文算法与其余算法在特征描述向量生成阶段的性能,实验中计算匹配正确率需要在剔除外点之前进行。测试图像中的图 8(a)和图 8(b)为相机处于不同视点所拍摄的图像,拍摄场景为机场,图像大小均为 480×640 ;图 8(c)和图 8(d)为同一场景的遥感图像,所采用的传感器

为 Urban SPOT band 3 及 TM band 4,拍摄的图像大小均为 256×256 ,2 幅待配准图像的拍摄时间不同、视角不同;图 8(e)和图 8(f)是 2 幅大小分别为 386×306 和 472×335 的遥感图像,且拍摄角度差异较大;图 8(g)和图 8(h)所示的海景图像的拍摄视角和光照条件均存在较大差异,它们的大小均为 480×640 ;图 8(i)和图 8(j)为 2 幅大小为 480×640 的航拍图像,实验选用的每一组测试图像的变换关系均未知。应用本文提出算法及文献[7]中算法重复进行 100 次实验,统计特征匹配的正确率及所用时间,实验结果如表 2 及表 3 所示。



(a)测试图像 1 (b)测试图像 2 (c) 测试图像 3 (d) 测试图像 4 (e)测试图像 5 (f)测试图像 6
(a)Test image 1 (b) Test image 2 (c) Test image 3 (d) Test image 4 (e) Test image 5 (f) Test image 6



(g) 测试图像 7 (h) 测试图像 8 (i) 测试图像 9 (j) 测试图像 10
(g) Test image 7 (h) Test image 8 (i) Test image 9 (j) Test image 10

图 8 测试图像
Fig. 8 Test images

表 2 本文方法进行特征匹配的正确率及匹配过程所用时间

Tab. 2 Accuracy ratio and time cost of feature point matching by proposed method

	特征点 数目	匹配 点对	正确匹 配点对	正确匹配点对 所占百分比	总时间 /s
Fig. 8(a)	551	189	158	83.59%	0.023
Fig. 8(b)	832	31	28	90.32%	0.021
Fig. 8(c)	317	149	132	88.59%	0.029
Fig. 8(d)	268	237	192	81.02%	0.034
Fig. 8(e)	349	689	378	88.31%	0.037
Fig. 8(f)	691				
Fig. 8(g)	1 005				
Fig. 8(h)	689				
Fig. 8(i)	849				
Fig. 8(j)	979				

表 3 SIFT 进行特征点匹配的正确率和匹配过程所用时间

Tab. 3 Accuracy ratio and time cost of feature point matching by using SIFT algorithm

	特征点 数目	匹配 点对	正确匹 配点对	正确匹配点对 所占百分比	总时间/s
Fig. 8(a)	551	129	117	90.69%	11.963
Fig. 8(b)	832	15	13	86.67%	4.538
Fig. 8(c)	317	77	63	81.82%	7.813
Fig. 8(d)	268	171	152	88.89%	15.456
Fig. 8(e)	349	315	279	88.57%	16.489
Fig. 8(f)	691				
Fig. 8(g)	1005				
Fig. 8(h)	689				
Fig. 8(i)	849				
Fig. 8(j)	979				

表 4 图 8(g)和 8(h)配准精度与所用时间

Tab. 4 Registration precision and time cost of Fig. 8(g) and Fig. 8(h)

所采用方法	正确匹配点 对百分比	RMSE	配准时间/s
The proposed method	87.5	0.42	0.053
Method proposed in [7]	86.9	0.45	15.378

将 2 幅图像之间正确匹配对的数目与 2 幅图像中检测到的较少的特征点数目之比定义为匹配分数。为了检验 e 的取值对检测器鉴别力的影响,匹配分数越大,证明检测器鉴别力越好,图 9 显示了 e 的取值与匹配分数之间的关系,横坐标为 e 的取值,纵坐标为图像对的匹配分数。图中

的曲线 1、2、3、4、5 与图 8 中 5 组图像一一对应,从图中可以看到,当 e 取值范围为 0.4~0.5 时,匹配分数最大,因此本文实验中 e 取值为 0.45。




图 9 匹配分数与 e 取值的关系

Fig 9 Relationship between matching score and e

为了定量分析特征匹配方法的图像配准的准确度。本文采取均方根误差(Root Mean Square Error, RMSE)作为匹配精度评定标准:

$$RMSE = \sqrt{\frac{\sum_{i=1}^k \| f(q_i', M) - p_i \|^2}{k}}, \quad (9)$$


其中: p_i 和 q_i' 是经过变换后的匹配点对集中的一对, k 为最终成功匹配的特征点对数。

图 10(a)为采用本文提出方法对图 8(g)和图 8(h)提取特征点并进行匹配后的结果,图 10(b)为配准的结果。本文算法与文献[7]方法的配准结果的定量评价如表 4 所示。由表 4 可知,2 种算法的配准准确率基本保持一致,但本文算法的运行速度有了很大提高,完全可以满足实时性的要求。其原因在于本文采用了更加高效的基于字典的描述子生成算法,字典采用离线的方式生成,在算法实际应用过程中,仅需调用存储在内存中的字典即可完成描述向量的计算。



(a) 特征匹配结果

(a) Results of feature matching



(b) 配准后图像
(b) Registration image

图 10 图 8(e)和图 8(f)特征匹配和配准后图像
Fig. 10 Results of feature matching and registration of Fig. 8(g) and Fig. 8(h)

4 结 论

本文提出了一种基于字典的描述向量生成算法并将其应用于图像配准。该方法首先利用

DOG 特征检测算法提取出训练图像库中的图像特征点,并产生特征区域图像 FPRI,然后利用 KSVD 算法训练字典。在线运行阶段,算法将实时图像的 FPRI 与字典中的基底图像进行比较,得到相似性度量,根据稀疏编码的原理,将该相似性度量作为特征点的描述向量。针对本文提出的 DFD 描述向量维数较高,搜索同名特征点过程中耗时较长的问题。本文采用 Silpa-Anan 等提出的随机 KD 树算法加速该过程,算法采用建立多个 KD 树取代使用单一 KD 树的方式增加了搜索节点的独立性,从而在保证正确匹配特征点的前提下,降低了搜索过程的耗时,加快了同名特征点的搜索过程。本文采用 RANSAC 方法剔除误匹配点对,通过使用正确的匹配点对估计待配准图像间的最优空间几何变换关系实现配准,所提的配准算法在基本不影响配准准确率的前提下,降低了配准过程中特征描述向量计算阶段以及同名特征点搜索阶段的耗时,可以以较快的速度实时完成图像配准。

参考文献:


- [1] 杨晓敏,吴炜,卿黎波,等. 图像特征点提取及匹配技术 [J]. 光学 精密工程, 2009, 17(9): 2276-2282.
YANG X M, WU W, QING L B, et al.. Image feature extraction and matching technology [J]. *Opt. Precision Eng.*, 2009, 17(9): 2276-2282. (in Chinese)
- [2] SONG Z L, LI S, GEORGE T F. Remote sensing image registration approach based on a retrofitted SIFT algorithm and Lissajous-curve trajectories [J]. *Optics Express*, 2010, 18(2): 513-522.
- [3] 孙辉,马天玮. 基于相位相关的目标图像亚像元运动参数估计 [J]. 液晶与显示, 2011, 26(6): 858-862.
SUN H, MA T W. Sub-pixel motion estimation based on phase-only correlation [J]. *Chinese Journal of Liquid Crystals and Displays*, 2011, 26(6): 858-862. (in Chinese)
- [4] 丘文涛,赵建,刘杰. 结合区域分割的 SIFT 图像匹配方法 [J]. 液晶与显示, 2012, 27(6): 827-831.
QIU W T, ZHAO J, LIU J. Image matching algo-
- rithm combing SIFT with region segment [J]. *Chinese Journal of Liquid Crystals and Displays*, 2012, 27(6): 827-831. (in Chinese)
- [5] WONG A. An adaptive monte Carlo approach to phase-based multimodal image registration [J]. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(1): 173-179.
- [6] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [7] 祁燕,王琰,王明宇. 改进的 SIFT 特征图像配准算法 [J]. 沈阳理工大学学报, 2012, 31(4): 50-53.
QI Y, WANG Y, WANG M Y. Improved SIFT feature image registration algorithm [J]. *Journal of Shenyang Ligong University*, 2012, 31(4): 50-53.
- [8] BAY H, TUYTELLARS T, GOOL L V. SURF: speeded up robust features [J]. *Computer Vision and Image Understanding*, 2008, 110(3): 346-359.
- [9] 张锐娟,张建奇,杨翠. 基于 SURF 的图像配准方法研究 [J]. 红外与激光工程, 2009, 38(1): 160-165.
ZHANG R J, ZHANG J Q, YANG C. Image regis-

- tration approach based on SURF [J]. *Infrared and Laser Engineering*, 2009, 38(1):160-165. (in Chinese)
- [10] CANDLES E J, ROMBERG J, TAO T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. *IEEE Transactions on Information Theory*, 2006, 52(2):489 - 509.
- [11] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD; An algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Transactions on Signal Processing*, 2006, 54(11):4311 - 4322.
- [12] JOLLOFFE I T. *Principal Component Analysis* [M]. New York: Springer, 2002.
- [13] ENGAN K, AASE S O, HUSOY J H. Multi-frame compression; Theory and Design [J]. *Eurasiip Signal Processing*, 2000, 80(10):2121 -2140.
- [14] SILPA-ANAN C, HARTLEY R. Optimised KD-trees for fast image descriptor matching [C]. *Computer Vision and Pattern Recognition*, 2008: 1 -8.
- [15] MUJA M, LOWE D G. Fast approximate nearest neighbors with automatic algorithm configuration [C]. *International Conference on Computer Vision Theory and Applications*, 2009:331 -340.

作者简介:



朱明(1964—),男,江西南昌人,工学硕士,研究员,博士生导师,主要研究方向为:数字图像处理、光电成像技术、电视跟踪和自动目标识别技术。E-mail: zhu_mingca@163.com



王健博(1984—),男,吉林白山人,博士研究生,主要从事机器视觉、自动目标识别、视频序列跟踪方面的研究。E-mail: mypostwww@163.com。

(版权所有 未经许可 不得转载)