

表3 不同算法在不同数据集上基于 Sensitivity 指标的聚类效果对比

Table 3 Comparison of clustering effects on different datasets of different algorithms for Sensitivity

| 算法 | 空手道 zachary | synthetic_spirals | synthetic_cassini | zahn_compound | fu_flame | synthetic_cuboid |
|--------------------|-------------|-------------------|-------------------|---------------|----------|------------------|
| LDDC | 0.95 | 1.0 | 1.0 | 0.999 | 1.0 | 1.0 |
| DDC | 0.938 | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 |
| k-means | — | 0.496 | 0.947 | 1.0 | 0.711 | 1.0 |
| k-medoids | 0.883 | 0.496 | 0.944 | 1.0 | 0.726 | 1.0 |
| DBSCAN | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 |
| Affinity | 0.374 | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 |
| Hierarchical | 1.0 | 1.0 | 1.0 | 1.0 | 0.989 | 1.0 |
| DensityCut | — | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 |
| SpectralClustering | 0.619 | 0.499 | 1.0 | 1.0 | 0.665 | 1.0 |
| MCODE | 1.0 | 0.788 | 1.0 | 0.816 | 0.499 | 0.852 |

结束语 本文提出了一种无参数峰值聚类算法 LDDC, 算法首先把待聚类数据集转换为一个加权完全图, 并将 Laplacian 中心性作为评价网络节点重要性的指标, 同时在此基础上提出了聚类算法。相比 DDC 需要提前设定截断距离作为算法的参数, 以及 k-means 等经典聚类算法需要提前设定经验参数, LDDC 实现了真正的无参数聚类, 可以在没有任何人为设定先验参数的情况下, 自动地对数据集进行聚类。该方法不但可以实现对传统数据集的聚类, 还可以用来探测复杂网络中的社团, 具有广阔的应用前景。

参考文献

- [1] GONDY L A, THOMAS C R B, BAYES N. Programs for machine learning[J]. Advances in Neural Information Processing Systems, 1993, 79(2): 937-944.
- [2] SUN J G, LIU J, ZHAO L Y. Research on clustering algorithm [J]. Journal of Software, 2008, 19(1): 48-61. (in Chinese)
孙吉贵, 刘杰, 赵连宇. 聚类算法研究 [J]. 软件学报, 2008, 19(1): 48-61.
- [3] HE L, WU L D, CAI Y C. A survey of clustering algorithms in data mining [J]. Application Research of Computers, 2007, 24(1): 10-13. (in Chinese)
贺玲, 吴玲达, 蔡益朝. 数据挖掘中的聚类算法综述 [J]. 计算机应用研究, 2007, 24(1): 10-13.
- [4] ZARE H Z, MOHAMMADZADEH M. Knowledge discovery from patients' behavior via clustering-classification algorithms based on weighted eRFM and CLV model: An empirical study in public health care services [J]. Iranian Journal of Pharmaceutical Research Ijpr, 2016, 15(1): 355-367.
- [5] TANG Y, ZHONG N J, FAN J. An improved recommendation algorithm based on user rating information [J]. Computer Science, 2016, 43(9): 111-115. (in Chinese)
汤颖, 钟南江, 范菁. 一种结合用户评分信息的改进好友推荐算法 [J]. 计算机科学, 2016, 43(9): 111-115.
- [6] HE B, DING Y, TANG J, et al. Mining diversity subgraph in multidisciplinary scientific collaboration networks: A meso perspective [J]. Journal of Informetrics, 2013, 7(1): 117-128.
- [7] MACQUEEN J, LECAM, LUCIEN M. Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability [M]. University of California Press, 1967: 281-297.
- [8] HAN X, LIU S F, XU T Q. An improved K-medoids algorithm based on genetic simulated annealing algorithm [J]. Journal of Jilin University (Engineering), 2015, 45(2): 619-623. (in Chinese)
韩啸, 刘淑芬, 徐天琦. 基于遗传模拟退火算法的改进 K-medoids 算法 [J]. 吉林大学学报(工), 2015, 45(2): 619-623.
- [9] ARTHUR D, VASSILVITSKII S. k-means++: the advantages of careful seeding [C] // Eighteenth Acm-Siam Symposium on Discrete Algorithms (SODA 2007). New Orleans, Louisiana, USA, 2007: 1027-1035.
- [10] SIMOUDIS E, HAN J, FAYYAD U, et al. Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining [M]. AAAI Press, 1996: 226-231.
- [11] ZHANG T, RAMAKRISHNAN R, LIVNY M, BIRCH; A New Data Clustering Algorithm and Its Applications [J]. Data Mining & Knowledge Discovery, 1997, 1(2): 141-182.
- [12] XIANG L M, ZHOU W B, ZHONG Y. Based on Gauss Process of improved CLIQUE algorithm [J]. Computer Application, 2015, 35(S2): 85-87. (in Chinese)
向柳明, 周渭博, 钟勇. 基于高斯过程的 CLIQUE 改进算法 [J]. 计算机应用, 2015, 35(S2): 85-87.
- [13] RODRIGUEZ A, LAIO A. Machine learning. Clustering by fast search and find of density peaks [J]. Science, 2014, 344(6191): 1492-1496.
- [14] ZHOU L, PEI C. Delta-density based clustering with a divide-and-conquer strategy: 3DC clustering [J]. Pattern Recognition Letters, 2016, 73(C): 52-59.
- [15] CHEN Y, ZHAO P, LI P, et al. Finding Communities by Their Centers [J]. Scientific Reports, 2016, 6: 24017.
- [16] LI Y, JIA C, YU J. A parameter-free community detection method based on centrality and dispersion of nodes in complex networks [J]. Physica A Statistical Mechanics & Its Applications, 2015, 438: 321-334.
- [17] NEWMAN M E. Analysis of weighted networks [J]. Physical Review E Statistical Nonlinear & Soft Matter Physics, 2004, 70(2): 056131.
- [18] CIMINI G, SQUARTINI T, GABRIELLI A, et al. Estimating topological properties of weighted networks from limited information [J]. Physical Review E Statistical Physics Plasmas Fluids & Related Interdisciplinary Topics, 2015, 92(4-1): 040802.

对数极坐标特征指导的迭代就近点法

周诗豪 张云

(昆明理工大学信息工程与自动化学院 昆明 650500)

(昆明理工大学云南省计算机技术应用重点实验室 昆明 650500)

摘要 在多模态图像,有光照、取向及尺度或纹理变化的图像,以及宽基线图像之间通常存在大的形貌畸变。然而,当前主流推广的双自举迭代就近点法(GDB-ICP)在配准这类图对时存在困难。主要原因是,该方法利用提取的尺度不变泡点(SIFT keypoint)来引导迭代就近点法(ICP),但在大畸变图像上提取的 SIFT 点是不可靠的。为此,提出了一种用对数极坐标特征点(LPF)来引导迭代就近点的图像配准新方法(LPF-ICP)。实验结果表明,LPF-ICP 方法成功地从 Rensselaer 数据组中的所有 22 对挑战性图对提取了可靠的 LPF 种子,并顺利实现了全图配准,而 GDB-ICP 方法则只完成了其中的 19 对,从而证实了 LPF-ICP 方法的有效性。

关键词 图像匹配,尺度不变特征点,对数极坐标空间,立体视觉

中图分类号 TP751.1 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.01.052

Log-polar Feature Guided Iterative Closest Point Algorithm

ZHOU Shi-hao ZHANG Yun

(School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

(Yunnan Key Lab for Computer Technology Applications, Kunming University of Science and Technology, Kunming 650500, China)

Abstract Images with lighting variations, rotation/optical zoom, physical changes of scene or at widely different view-points, can substantially change their appearance and shape when they are acquired using different modalities. Even with the state-of-the-art technology, e. g. , the generalized dual-bootstrap iterative closest point (GDB-ICP) method, it is still difficult to register those challenging images. The reason is that the GDB-ICP method uses the scale-invariant blob points (or SIFT keypoints) to drive the iterative closest point method (ICP). However, the SIFT keypoints cannot be reliably extracted from images with large appearance changes. To handle this issue, this paper proposed a novel log-polar feature guided iterative closest point (LPF-ICP) algorithm for image registration. The experimental evaluation illustrates that the LPF-ICP method can reliably extract the log-polar feature points and successfully register all the 22 image pairs contained in the Rensselaer dataset, while the GDB-ICP method only succeeds in 19 of them, thus verifying the effectiveness of the proposed method.

Keywords Image registration, Scale-invariant feature point, Log-polar space, Stereo vision

1 引言

通过估算空间变化或配准模型来实现数字图像的配准(image registration)是图像处理的基本工作,也是图像拼接^[1]、运动补偿^[2]、立体视觉^[3]等诸多应用的基础。图像配准通常通过比较两图像重叠区形貌的相似性来实现,由 4 个部分组成:特征空间、相似性测度、搜索空间及搜索方案^[4]。目前常用的特征空间有两类:1)图像的灰度轮廓,适合描述图区的外貌(或纹理)^[3,5-8];2)图像的光度及几何特征,适合描述图区的外形(或结构)^[1,9]。

在图像灰度的特征空间上,常采用 3 类相似性测度,即互

信息(MI)^[7-8]、差方和(SSD)^[5]和归一化互相关(NCC)^[10],来定量比较两帧图像的相似性。而在图像特征的特征空间上,一般采用与特征本身的几何性质相符的距离测度^[9]。例如,对于泡点^[11]及角点^[12],用欧氏距离来测度;而对于边缘点^[13],则用法向距离来测度。

二维(2D)图像间的畸变类型不同,适用的空间变换(或配准模型)也不同。例如,对同一平面景物所拍摄的两帧宽基线图像之间需要一个 2D 射影变换(projective transformation)或 2D 单应矩阵(homography)^[14];一个球形景物的不同图像之间需要一个二次函数(quadratic)变换^[15]。另外,为了防止对小数据的过度拟合,一般采用一个模型序列(而非单一

收到日期:2016-12-26 返修日期:2017-03-31 本文受国家自然科学基金项目(61262043),云南省科技计划项目(2011FZ029)资助。

周诗豪(1993-),男,硕士生,主要研究方向为计算机视觉、图像处理,E-mail:772881831@qq.com(通信作者);张云(1963-),男,博士,教授,主要研究方向为计算机视觉、图像处理。

模型),通过评价多个模型估值的精度与稳定性来决定谁更符合配准。因此,实际上,可采用两个不同的模型序列^[9]。

有了恰当的配准模型后,图像配准问题就转化为最近模型参数搜索(或求解)问题。实际上,常用的是某种健壮的搜索方案,例如加权迭代最小二乘法(Iteratively-Reweighted Least-Squares, IRLS)^[16]。另外,配准模型可分为模型参数的线性或非线性函数。在上述两种模型序列中,射影模型与射影加经向畸变模型为非线性模型,其余的则为线性模型。相应地,可以进一步将相应的 IRLS 方法细分为线性 IRLS 与非线性的 IRLS。前者利用模型参数解析解的方式,而后者可以按 Levenberg-Marquardt 数值算法^[17]的方式,来分别搜索参数的最佳估值。另外,迭代法的收敛区间一般较窄,需要为其提供一个初始解来引导随后的优化过程。通常,一个模型序列中的简单模型就是高阶复杂模型的初始解。

图像配准虽然在过去的一二十年的持续研究下已取得了不少进展^[5],但仍然面临不少挑战。主要原因在于:1)照相机的观测点不同,有大旋转及变焦,多模态;2)景物存在光照与物理外貌的变化。而 Rensselaer 数据组^[9]所搜集的 22 对图像就是这类图像的典型代表,其中一些图像是特意在不同季节拍摄的,景物表面有不同覆盖物,使图像间的纹理差异较大,仅结构有对应关系。用基于灰度的配准方法来处理这类大畸变图像是不适合的。这类图像间存在的结构相关性,为基于特征的配准方法提供了出发点, Yang 提出的双自举迭代就近点法(Generalized Dual-Bootstrap Iterative Closest Point, GDB-ICP)^[9]就是这类基于特征方法中的佼佼者。该方法将尺度不变特征变换点(Scale-Invariant Feature Transform, SIFT)作为初始种子,22 对图像中成功配准了 19 对,而失败的 3 对图像主要是因为无法提取正确的 SIFT 种子。其后, Tsai 等^[18]进一步用边缘的区域特征来增强 GDB-ICP 方法,从而提高了对多模态荧光血管造影图像的配准率。然而,该改进方法仍采用 SIFT 种子,因而对 3 对失败的 Rensselaer 图像对并无益处。同理,基于 SIFT 点的配准方法^[1,9]或其加速算法^[19-20]也无法实现上述 3 对图像的配准。

为了处理这类具有挑战性的图像,提高配准成功率,本文提出了一种用对数极坐标特征来引导迭代就近点(Log-Polar Feature guided Iterative Closest Point algorithm, LPF-ICP)的图像配准新方法。与 GDB-ICP 方法类似,LPF-ICP 配准方法分为种子与长大两个步骤。首先,用 LP 种子点匹配来确定初始引导区。其次,用迭代就近点法(Iterative Closest Point, ICP)^[21-23]来逐步扩张引导区并升级其配准模型,直到该区域覆盖整个重叠区为止。另外,LPF-ICP 方法在以下两方面进行了创新:1)改进了配准阶段所使用的技术。首先,在初始化阶段,GDB-ICP 方法应用 SIFT 关键点^[11]作为种子点,但却发现从大畸变图像上提取 SIFT 关键点存在困难^[9]。考虑到 SIFT 关键点是在高频信息有损^[24-25]的尺度空间上获取的,本文提出了一个针对性的在信息无损的图像对数极空间上的尺度不变角点检测器(Log-Polar Corner Detector, LPCD),LPCD 能检测尺度不变 LP 角点。结合之前提出的对数极坐

标极点检测器(Log-Polar Bulb Detector, LPBD)^[26]所提取的尺度不变 LP 泡点,LPF-ICP 方法将 LP 特征点(包括 LP 角点及 LP 泡点)作为种子点,并通过匹配来获得对应 LP 种子点之间的相似模型估值,同时形成初始引导区。其次,在种子长大阶段,GDB-ICP 方法在 SIFT 高斯金字塔内驱动 ICP。LPF-ICP 方法对上述驱动方式进行了进一步简化,即只采用在原始图像上的单尺度特征点来驱动 ICP,以逐步扩张引导区并升级配准模型。2)通过整合技术,设计出了按 LP 种子点长大方式来配准图像的新算法。同时,对 LPF-ICP 算法在配准 Rensselaer 数据集^[9]时的性能进行了评价,结果可用于证实 LP 种子点的可靠性以及应用于单尺度特征点来驱动 ICP 实现配准的有效性。

2 算法框架

本文提出一种按 LP 种子点长大方式来配准源图像 I 与目标图像 I' 的 LPF-ICP 方法,其流程图如图 1 所示。该图像的配准过程分两步完成。

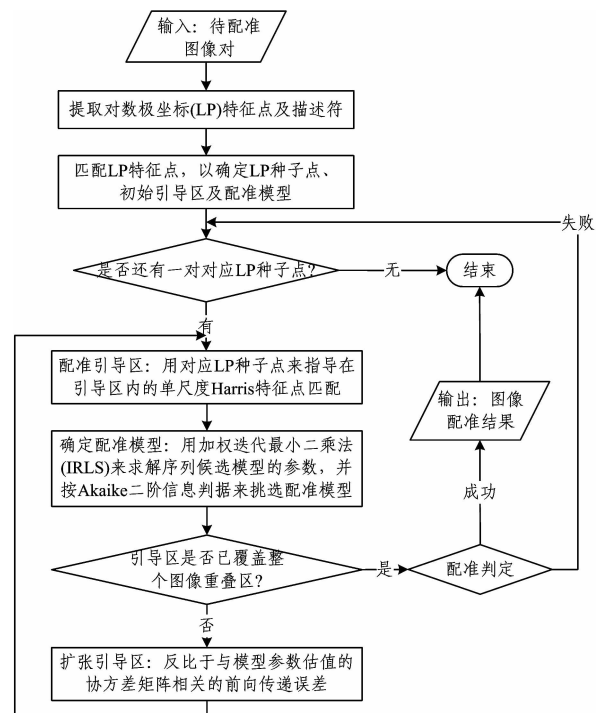


图 1 LPF-ICP 图像配准流程图

Fig. 1 Flow chart of LPF-ICP image registration

首先,用 LP 种子点匹配来确定初始引导区。这个初始化方法由 3 个具体步骤组成:1)提取尺寸不变 LP 特征点及描述符,该步骤可以细分为两个部分,即用本文提出的 LPCD 方法提取 LP 角点及描述符,以及用前期提出的 LPBD^[26]方法提取 LP 泡点及描述符;2)用描述符间的欧氏距离来确定一个 LP 特征点在另一帧图像上的对应点,并对所得对应 LP 特征点进行排序;3)为了消除一对多响应的干扰,只保留局部响应最强的特征点。

其次,用 ICP 法逐步扩张引导区并升级其配准模型,直到该区域覆盖整个重叠区为止。具体来说,将初始化阶段的对应 LP 特征点作为种子点,并由对应 LP 种子点导出相似模型估

值,形成初始引导区。由此便进入种子长大阶段。如果存在一对对应 LP 种子点,则用这种单尺度 Harris 特征点(包括 Harris 角点及边点)来驱动 ICP,以逐步扩张引导区并升级配准模型,直到引导区成功地覆盖整个图像的重叠区为止。

3 LP 特征点检测与单尺度特征的 ICP

3.1 节描述图像配准的初始化阶段所提出的 LP 特征点的提取方法;3.2 节则介绍对在图像配准的种子长大阶段所采用的单尺度特征点驱动的 ICP 方法。

3.1 对数极坐标特征点的提取

对数极坐标特征点的提取包括 3 个方面:Harris 特征点的提取、尺度不变描述符的提取以及相似测度。

3.1.1 Harris 特征点的提取

从一帧图像 $I(x)$ 中提取 Harris 角点^[12]的过程可分为 3 个步骤进行。

首先,计算每个像素位置 x 处的自相关矩阵 $M(x)$:

$$M(x) = \sum_{x_i \in W(x)} g(x-x_i) \nabla I(x_i) \nabla^T I(x_i) \quad (1)$$

其中, ∇ 为梯度算子, $W(x)$ 为 x 的 7×7 邻域, $g(\cdot)$ 为高斯权重函数。

接着,计算 $M(x)$ 的本征值比率 $r_M = \frac{\lambda_1(x)}{\lambda_2(x)}$ ($\lambda_1(x) < \lambda_2(x)$)。

如果 $r_M > 0.1$,则说明在 x 处的两个独立方向上有明显的灰度变化,可判定该点为候选角点。

最后,执行非最大抑制。如果候选角点 x 的响应(定义为 $M(x)$ 的迹)在其 8 邻域中是最大的,则接受该点为正式角点;否则,拒绝该候选角点。

3.1.2 尺度不变描述符的提取

LP 角点描述符需要先确定一块该角点的邻域,再借助该图块内的图像性质来代表它。需指明,如果选取图块时考虑了取向与尺度相对一致性,则提取的描述符就对图像旋转和缩放具有不变性。

要使描述符具有尺度不变性,则需要明确图块的特征尺度 s_c (characteristic scale),并依据该尺度来确定提取描述符的位置。之前的工作^[13,27]表明,泡点的灰度径向梯度响应随着尺度的变化会出现极值。响应极值处的尺度被称为该泡点的特征尺度 s_c 。角点自身并无特征尺度现象,其特征尺度可用邻近泡点的特征尺度来代替。用 LPBD 方法提取泡点后,泡点的特征尺度可以方便地从对数极坐标图块上提取^[26],具体过程如下。

(1) 给定直角坐标 (x, y) 下的一个以某泡点为中心、半径为 r_e 的圆图块(见图 2(a)),并将其按以下坐标变换公式:

$$\begin{cases} \log_r r = 0.5 \log_r (x^2 + y^2) \\ \theta = \tan^{-1}(y/x) \end{cases} \quad (2)$$

将其转化为对数极坐标 $(\log_r r, \theta)$ 下的 $w_1 \times h$ 矩形图块(见图 2(b)),其尺寸 w_1 与 h 定义如下:

$$\begin{cases} t = r_e / (r_e - 1) \\ w_1 = \log_r t \end{cases} \quad (3)$$

$$\begin{cases} \Delta\theta = 2 \sin^{-1}(0.5/r_e) \\ h = 360/\Delta\theta \end{cases} \quad (4)$$

其中, t 为对数底数, $\Delta\theta$ 为极角采样间隔。


(2) 如图 2(b)所示,沿着横轴由左至右移动一个与图块等高且宽为 w_2 ($w_2 = 3$) 的响应窗口 W ,同时按式(5)来计算灰度径向梯度响应 R :

$$R = \sum_W \frac{\partial I}{\partial r} = \sum_W \frac{1}{r \ln t} \frac{\partial I}{\partial \log_r r} \quad (5)$$

而响应局域极值处的位移 s 所对应的极径 s_c 就是泡点的特征尺度,其表达式如下:

$$s_c = t^s \quad (6)$$

其中, s 等价于 $\log_r s_c = \arg \max_{\log_r r} R$ 。



(a) 半径为 r_e 的直角坐标圆图块 (b) $w_1 \times h$ 对数极坐标矩形图块


图 2 确定特征尺度 s_c

Fig. 2 Detection feature scale s_c

其次,要使描述符具有旋转不变性,需要明确图块的取向 α_c ,实现在一个一致性取向向下提取描述符。采用图块的灰度梯度取向来定义图块的取向,具体提取过程如下。

(1) 对于在特征尺度 s_c 下的特征图块 W_c (见图 3(b)),预先计算在对数极坐标系下其像素灰度 $I(\log_r r, \theta)$ 的梯度幅值 $m(\log_r r, \theta)$ 与取向 $\alpha(\log_r r, \theta)$:

$$\begin{cases} m(\log_r r, \theta) = \frac{1}{r} \sqrt{\frac{1}{\ln^2 t} \left(\frac{\partial I}{\partial (\log_r r)} \right)^2 + \left(\frac{\partial I}{\partial \theta} \right)^2} \\ \alpha(\log_r r, \theta) = \theta + \tan^{-1} \left(\frac{\partial I}{\partial \theta} / \left(\frac{1}{\ln t} \frac{\partial I}{\partial (\log_r r)} \right) \right) \end{cases} \quad (7)$$



(a) 窗口定位(窗口以特征尺度 s_c (b) 窗口旋转(将纵轴原点平移到对应的横轴位移 s 为对称轴) 图块取向 α_c 处)

图 3 确定特征窗口 W_c 的两个步骤

Fig. 3 Two steps to determine the feature window W_c

(2) 制作图块的取向直方图,其组数为 36,组距为 10° ,实现了 360° 全角度覆盖。在把每个角度数据 $\alpha(\log_r r, \theta)$ 列入相应的组时,其计数需要用幅值 $m(\log_r r, \theta)$ 和高斯环形函数来双重加权。

(3) 直方图上的局域峰对应着梯度的占优方向,因此确定

为图块的取向 α_c 。另外,还要对峰位及其左右 3 组频数进行抛物线拟合,以获得更精确的峰位估值。

有了特征点坐标、特征尺度 s_c 及图块取向 α_c 后,就可以构建尺度不变描述符。将对数极坐标图块的灰度梯度的取向直方图作为该点的对数极坐标描述符^[26],其具体过程描述如下:1)在对数极坐标下,确定一个与图块等高且宽为 w_c ($w_c = 15$) 的特征窗口 W_c (见图 3(a)),将该窗口进一步细分为 m ($m=8$) 行 n ($n=3$) 列共 24 个子块;2)为各子块建立一个梯度取向直方图,其组数为 8,组距为 45° ;3)通过组合所有子块的直方图并归一化得到一个 192 维的描述符矢量 D_c 。以特征尺度 s_c 的位置 s 为对称轴来定位特征窗口 W_c (见图 3) 可以使 D_c 具有缩放不变性。进一步,将对数极坐标系的纵轴沿角向环形平移,直至原点到达图块取向 α_c 为止(见图 3),可以使 D_c 具有旋转不变性。

3.1.3 相似测度

对于匹配两帧图像之间的 LP 特征点(包括角点与泡点),具体针对两帧图像即源图像 I 与目标图像 I' 而言,如果在 I 上的特征点 x 能与在 I' 上的特征点 x' 互相匹配(或对应),则表明这一对对应点来自同一景点。 x 与 x' 对应与否是由描述符 $D_c(x)$ 与 $D_c(x')$ 是否相似来判定的。为此,采用两描述符之间的欧氏距离作为相似性测度。一般来说,欧氏距离越小,两描述符就越相似;反之,则越不相似。根据相似度的大小,可以对对应特征点进行排序。

3.2 单尺度特征点驱动的 ICP 方法

种子局域长大至全域图像配准是一个用对应种子间的初始空间变换来引导匹配其邻域内的角点及边点的迭代过程,具体由以下几个步骤组成。首先,由对应种子获取相应的初始引导区以及它们之间的相似变换;接着,通过迭代扩大引导区直至收敛;最后,用配准测度来评价配准结果的正确性。下面对这些配准部分进行具体阐述。

3.2.1 引导区配准

引导区配准是用源引导区与目标引导区之间的初始配准模型来指导区内单尺度特征的匹配,具体过程如下。

首先,初始引导区是对应 LP 角与泡点(也即 LP 种子点)为中心的方形图块。

接着,确定在引导区内的 Harris 特征点。基层原始图像上的信息较其他层级图像的信息更丰富,仅考虑用在原始图像上提取单尺度特征点来驱动 ICP 方法。先提取图像上的 Harris 角点与边点。1)对于每一像素 x ,计算其自相关矩阵 $M(x)$ 。2)根据 $M(x)$ 本征值比率 $r_M = \frac{\lambda_1(x)}{\lambda_2(x)}$ ($\lambda_1(x) < \lambda_2(x)$) 的大小来判断特征类型。如果 $r_M < 0.1$,说明 x 只在一个独立方向上有明显的灰度变化,则可判定该点为候选边点;否则,判断其为候选角点。3)按特征点的响应(定义为 $M(x)$ 的迹)来执行非最大抑制。如果候选角点 p 的响应在其 8 邻域中是最大的,或者边点在其沿法向的 2 近邻中是最大的,则接受该点为正式特征点;否则拒绝该候选点。

最后,用初始模型来指导引导区内的单尺度特征点匹配,产生对应角点集 S_c 与边点集 S_e 。选择初始模型时,存在两种情况。对于由对应 LP 种子点生成的初始引导区,初始模

型应是尺度不变 LP 种子点之间固有的相似模型。该模型涉及 3 个独立参数,分别是对应种子点 (x, x') 之间的位移 $(x' - x)$ 、取向差 $(\alpha_c(x') - \alpha_c(x))$ 以及特征尺度比 $(s_c(x')/s_c(x))$ 。对于扩张更新过的引导区,初始模型则应为更新前的引导区的最终模型。另外,为了适应迭代扩张中数据量的不断增长,后续模型应与之前的同等或更复杂。

3.2.2 配准模型的确定

有了关于引导区的对应特征点集合、初始配准模型与初始标准偏差后,本文采用加权迭代最小二乘法(IRLS)来求解使 Tukey 双权重目标函数^[28]极小的序列候选模型的参数最佳估值,并按 Akaike 二阶信息判据^[29]来从中挑选适合的配准模型。下面首先介绍模型最佳参数的具体求解过程。

首先,给定对应角点集 S_c 与边点集 S_e ,采用对应角点的欧氏距离 d_c 和边点的法向距离 d_e 健壮的目标函数如下:

$$E(\alpha; S_c, S_e) = \sum_{(x_i, x'_i) \in S_c} w_{c,i} \rho(d_c(x_i, x'_i; \alpha) / \sigma_c) + \sum_{(x_i, x'_i) \in S_e} w_{e,i} \rho(d_e(x_i, x'_i; \alpha) / \sigma_e) \quad (8)$$

其中, $\rho(\cdot)$ 为 Tukey 双权重损失函数, w_t 为对应特征点 ($t=c$ 为角点, e 为边点) 的相似性测度, σ_t 为用于对 d_c 与 d_e 进行归一化的对应特征点的标准偏差。下面分别给出这些参数的计算公式。

首先, Tukey 损失函数 $\rho(\cdot)$ 由下式定义:

$$\rho(u) = \begin{cases} \frac{a^2}{6} [1 - (1 - (u/a)^2)^3], & |u| \leq a \\ \frac{a^2}{6}, & |u| > a \end{cases} \quad (9)$$

其中, a ($a=4$) 为参数。

其次,对应角点与边点的相似性测度 w_c 与 w_e 则按下式计算:

$$\begin{cases} w_c = \min(s_x'/s_x, s_x/s_x') \\ w_e = \min(s_x'/s_x, s_x/s_x') |v_x^T v_{x'}| \end{cases} \quad (10)$$

其中, $s_{x'}$ 为特征点 x' 的尺度, s_x 为特征点 x 经模型 α 变换后的尺度, v_x 为边点 x' 的法向矢量, $v_{x'}$ 为边点 x 经 α 变换后的法向矢量。

最后,对应特征点的标准偏差 σ_t 由下式计算:

$$\sigma_t^2 = \frac{\sum_{(x_i, x'_i) \in S_t} w_{d,i} w_{t,i} d_t^2(x_i, x'_i; \alpha)}{\sum_{(x_i, x'_i) \in S_t} w_{d,i} w_{t,i}} \quad (11)$$

其中, w_d 为对应特征点的权重,由标准偏差 σ_t 来对 Tukey 函数 ρ 的衰减因子 w 进行类型归一化,得到:

$$w_d = w(d_t(x, x'; \alpha) / \sigma_t) / \sigma_t^2 \quad (12)$$

由于 w 为 Tukey 函数 ρ 的衰减因子,即 $\rho = 0.5w\omega^2$,因此整理式(9)一式(12)可得 $w = \frac{1}{u} \cdot \frac{\partial \rho}{\partial u}$ 。

进一步,用加权迭代最小二乘法(IRLS)^[6]可以求解使目标函数(8)极小的模型参数 α 的最佳值。另外,配准模型可划分模型参数的线性或非线性函数。在本文所采用的两种模型序列中,射影模型与射影加经向畸变模型为非线性模型,其余的则为线性模型。据此,可以进一步将相应的 IRLS 方法细分为线性 IRLS 与非线性的 IRLS。前者利用模型参数解析解的方式,而后者按 Levenberg-Marquardt 数值算法^[17]的方式,来分别求解参数的最佳估值。

考虑到在迭代过程中不断扩容的数据可以提供更多的约束以估算更复杂的模型,本文采用两个模型序列,一个适用于自然图像的配准,包括相似、仿射、射影变换以及径向透镜畸变叠加射影变换;另一个则适用于视网膜图像的配准,包括相似变换、简化的以及无简化的二次函数。每次迭代中,除了要对上次迭代所得的老模型的参数估值进行更新,还要对序列中复杂度高一阶的新模型进行参数估算。然后,用综合衡量拟合精度与稳定性所造成的信息丢失的 Akaike 二阶信息判断[29]来从中挑选适合的配准模型。

3.2.3 引导区扩张

引导区的更新按各条边缘独立向外移动的方式来实现。下面以源引导区的一条边缘的移动为例来加以说明。

边缘的移动是用该边缘中点 x 沿其外法向 v 上的扩张率 δx 来定义的,而 δx 是根据当前模型参数估值的不确定性来确定的。如果将 x 变换到 x' 处的传递误差为 $\Sigma_{x'}$,则这种不确定性可由 $\Sigma_{x'}$ 在由 v 变换得到的 v' 方向上的投影 $v'^T \Sigma_{x'} v'$ 来定量。总之, δx 与 v' 方向上的传递误差 $v'^T \Sigma_{x'} v'$ 成反比,由下式计算:

$$\delta x = \beta \frac{\| (x - x_0) \|}{\max(1, v'^T \Sigma_{x'} v')} v_i \quad (13)$$

其中, $\beta(\beta=10)$ 为扩张率系数, x_0 为引导区的中心, $v=(x-x_0)/\|x-x_0\|$,而 $\Sigma_{x'}=J\Sigma_{\alpha}J^T$, Σ_{α} 是由目标函数式(8)的 Hessian 矩阵($\partial^2 E(\alpha)/\partial \alpha \partial \alpha$)的逆来定义的参数估值 α 的协方差矩阵, $J(J=\partial f(x,\alpha)/\partial \alpha)$ 是空间变换 $x'=f(x,\alpha)$ 的 Jacobian 矩阵。

3.2.4 配准判定

在引导区已扩张至两帧图像的整个重叠区后,需要评判引导区配准的正确性。为了与 GDB-ICP 方法[9]作比较,本文使用该方法所提出的 3 种评价测度:由平均加权误差定义的配准精度 ϵ_a 、由传递误差[30]导出的配准稳定性 ϵ_s 以及用对应边点的取向差的 Bhattacharyya 距离来定义的配准一致性 ϵ_c ,其定义如下:

$$\begin{cases} \epsilon_a = \frac{\sum_{(x_i, x'_i) \in S_e} \tau w_{d,i} \tau w_{e,i} d_{e,i}}{\sum_{(x_i, x'_i) \in S_e} \tau w_{d,i} \tau w_{e,i}} \\ \epsilon_s = \max_i \sqrt{\text{trace}(\Sigma_{x'_i})} \\ \epsilon_c = 1 - \sum_i \sqrt{h_i(\alpha, S_e) h_i'} \end{cases} \quad (14)$$

其中, $\Sigma_{x'}$ ($\Sigma_{x'}=J\Sigma_{\alpha}J^T$)为匹配 x 的误差协方差矩阵, $h_i(\alpha, S_e)$ 为对应边点的绝对取向差直方图的第 i 组频数, h_i' 为指数分布 $h'(\theta, \lambda) = \lambda e^{-\lambda \theta}$ ($\lambda=4.7$)直方图的第 i 组频数。

进一步,为上述 3 种评价测度(即精度 ϵ_a 、稳定性 ϵ_s 与一致性 ϵ_c)设定相应的阈值 τ_a ($\tau_a=7.3$), τ_s ($\tau_s=3.0$) 与 τ_c ($\tau_c=0.3$),并按如下配准判据来评价配准结果的正确性:

$$\epsilon_a < \tau_a, \epsilon_s < \tau_s, \epsilon_c < \tau_c \quad (15)$$

如果误差都低于所设定的阈值,则配准正确。

4 实验结果及分析

为了与 GDB-ICP 方法[9]进行比较,采用配准成功率(满足配准判据(15))、配准误差(即式(14)中的 ϵ_a)和时间开销这

3 项性能指标,以及 Rensselaer 测试数据组[9],并在此基础上对 LPF-ICP 图像配准方法的性能进行了评价。在数据组所搜集的 22 对图像中包含着多种针对性的成像因素,比如,类型多样的自然和人造景观、多模态、仅为 2% 的小重叠度、绕主光轴 90° 的大旋转、6.4 倍光学变焦产生的大尺度变化、宽基线以及有大光照或物理外貌变化的景物。

根据 LP 种子点提取到 ICP 长大的配准流程,下面分别介绍 LP 种子点提取以及对 22 对图像对的配准解结果,同时与当前国际主流的针对挑战性图像的 GDB-ICP 方法[9] 和 SIFT 方法[1,9]的图像配准结果进行对比。

4.1 LP 种子点提取

LP 种子的特征尺度 s_c 的取值范围会受到图块尺寸的限制。因此,应按预计 s_c 值的大小来调整图块的尺寸。首先,对于尺度变化低于 4 倍的图对,采用半径 r_e 定为 30 像素或更小的圆形图块。另外还存在两个例外:1)图对的尺度变化极大,例如 Extreme Zoom 图对有 6.4 倍的尺度变化,此时 r_e 应增至 60 像素;2)图对的重叠区极小,例如 Dashpoint 图对只有 2% 的重叠区(宽为 40 像素),此时 r_e 应降至 20 像素。最后,考虑到圆形图块的中心区域像素较少,从此区中提取的 s_c 的可靠性不高,因此仅保留那些从中心区之外(比如半径 $\geq \sqrt{5}$ 像素)提取的 s_c 。

在上述实验条件下,从 22 对图对中获取了 LP 特征对应点。其中,每一图对只选取排序前 100 位的 LP 对应点(角点与泡点各占一半)作为候选种子。同时,将定位误差小于 6 像素、取向差小于 20° 并且尺度比在 $[0.8, 1.25]$ 之间的 LP 种子定义为一致性的种子,结果如表 1 所列,并且在图 4 中用连线对这些种子点间的对应关系进行了展示。

表 1 用 LPF-ICP 方法从 22 对图对中提取种子的结果与 GDB-ICP 方法[9]的结果比较

Table 1 Separation of seeds from 22 pairs of maps using LPF-ICP method compared with GDB-ICP method[9]

| 图对名称 | 尺寸 | LPF-ICP | GDB-ICP |
|-------------------------|-----------|---------|-----------|
| | | LP 种子点数 | SIFT 关键点数 |
| Boston | 1712×1368 | 23 | >50 |
| Boston Library | 1504×1000 | 8 | >50 |
| Brain T1-PD | 512×512 | 5 | 9 |
| Brussels | 1712×1368 | 30 | >50 |
| Brugge Square | 1712×1368 | 14 | >50 |
| Brugge Tower | 1712×1368 | 44 | >50 |
| Capital Region | 1712×1368 | 6 | 6 |
| Dashpoint (2%重叠区) | 2048×1536 | 5 | 17 |
| Summer Night-Winter Day | 1504×1000 | 3 | 0 |
| Night-Day (Summer) | 1504×1000 | 3 | 30 |
| Summer-Winter (Day) | 1504×1000 | 3 | 21 |
| White Tower | 1504×1000 | 3 | 6 |
| Eiffel | 1712×1368 | 30 | >50 |
| EO-IR 1 | 300×236 | 3 | 4 |
| EO-IR 2 | 676×280 | 3 | 0 |
| Grand Canyon 1 | 1184×780 | 9 | 45 |
| Grand Canyon 2 | 900×568 | 10 | 12 |
| Melanoma | 1156×880 | 3 | 3 |
| Retina | 1600×1200 | 4 | 12 |
| Extreme Zoom | 1504×1000 | 3 | 41 |
| Satellite | 2878×2878 | 20 | >50 |
| White Board | 1504×1000 | 3 | >50 |

(续表)

| 图对名称 | 源图点位置/ 像素 | 目标图点定位/像素/ | | | 取向/ $^{\circ}$ | | | 尺度 | | |
|-------------------------|--------------|------------|----------|-------|----------------|---------|---------|-------|-------|-------|
| | | 实测值 | 真实值 | 误差 | 实测值 | 真实值 | 取向差 | 实测值 | 真实值 | 尺度比 |
| Capital Region | 916,1057 | 190,840 | 191,839 | 1.414 | -14.904 | -14.249 | -0.655 | 0.965 | 0.883 | 1.093 |
| Dashpoint (2%重叠区) | 2020,1403 | 43,1362 | 43,1361 | 1.000 | -0.967 | 1.361 | -2.328 | 1.009 | 1.038 | 0.972 |
| Summer Night-Winter Day | 1827,1656 | 715,533 | 715,533 | 0.000 | 33.994 | 31.874 | 2.120 | 0.203 | 0.210 | 0.967 |
| Night-Day (Summer) | 1214,792 | 440,426 | 441,426 | 1.000 | 38.199 | 36.512 | 1.687 | 0.487 | 0.502 | 0.97 |
| Summer-Winter (Day) | 367,710 | 688,428 | 689,426 | 2.236 | 1.204 | -4.639 | 5.843 | 0.435 | 0.418 | 1.041 |
| White Tower | 573,453 | 1082,677 | 1080,678 | 2.236 | -0.061 | 1.210 | -1.271 | 0.688 | 0.700 | 0.983 |
| Eiffel | 869,195 | 164,759 | 164,759 | 0.000 | 2.944 | -1.531 | 4.475 | 1.008 | 1.049 | 0.961 |
| EO-IR 1 | 436,86 | 416,129 | 416,129 | 0.000 | 0.942 | 0.303 | 0.669 | 1.072 | 0.954 | 1.123 |
| EO-IR 2 | 268,157 | 294,205 | 295,204 | 1.414 | -15.629 | -4.289 | -11.340 | 0.897 | 0.771 | 1.163 |
| Grand Canyon 1 | 682,329 | 793,98 | 793,98 | 0.000 | 4.482 | 2.440 | 2.042 | 1.026 | 0.974 | 1.053 |
| Grand Canyon 2 | 265,454 | 338,445 | 337,445 | 1.000 | 0.573 | 2.053 | -1.48 | 0.987 | 0.963 | 1.025 |
| Melanoma | 512,464 | 254,503 | 255,503 | 1.000 | -3.300 | -2.049 | -1.251 | 1.034 | 0.997 | 1.037 |
| Retina | 1062,429 | 362,212 | 363,212 | 1.000 | -11.258 | -17.513 | 6.255 | 1.056 | 0.979 | 1.079 |
| Extreme Zoom | 880,789 | 792,541 | 793,541 | 1.000 | 2.259 | -1.236 | 3.495 | 0.156 | 0.155 | 1.006 |
| Satellite | 492,274 | 171,253 | 171,253 | 0.000 | -78.801 | -76.629 | -2.174 | 0.941 | 0.949 | 0.991 |
| White Board | 314,1153 | 266,660 | 266,661 | 1.000 | -18.715 | -3.816 | -14.899 | 0.587 | 0.542 | 1.083 |

比较而言,SIFT关键点为GBD-ICP方法^[9]配准19对图对提供了种子点,LP特征点则对LPF-ICP方法配准所有22对图对进行了初始化。具体来看,在GDB-ICP方法初始化失败的3对图对中,Capital Region图对有宽基线造成的大射影畸变,Summer Night-Winter Day图对有光照与外貌变化造成的形貌畸变,而EO-IR 2图对则有多模态成像造成的形貌畸变,从而使得在有高频信息有损的图像尺度空间上获取的SIFT关键点不太可靠。相对而言,在信息无损的对数极空间上获取的LP特征点则较为可靠。

4.2 图像配准

在图像配准阶段,只有初始引导区的边长这一个参数需要调整。一般情况下,边长定为200像素,但存在下面两种例外情况:1)对于重叠区较小的图像对,如Dashpoint图对与

Boston Library图对而言,边长定为60像素;2)对于有大光照及焦距变化的图像对,如Extreme Zoom图对与Summer Night-Winter Day图对而言,边长则定在300像素。最后,LP种子点所提供的初始模型为相似变换,但是对于有大射影畸变的Capital Region图对,初始相似变换为最终的全图配准带来了较大的误差(10像素)。为了解决此问题,采取了一个改进的初始化方法,即在LP种子点处,再用一维匹配方法^[31]提供一个初始引导区的仿射变换作为初始变换来对该图对配准进行初始化。

LPF-ICP方法的配准性能结果如表3所列;配准的视觉结果如图5所示,每对图像的左图为源图像,而右图为其上被源图像覆盖的目标图像。

表3 用LPF-ICP方法配准Rensselaer数据组中22对图像的结果与GDB-ICP方法的结果比较

Table 3 Comparisons of 22 pairs of images on Rensselaer data set between LPF-ICP method and GDB-ICP method^[9]

| 图对名称 | 尺寸 | LPF-ICP | | GDB-ICP | | LPF-ICP | GDB-ICP |
|-------------------------|-----------|-----------------------|------|-----------------------|------|---------|---------|
| | | 配准误差 ϵ_a /像素 | 配准模型 | 配准误差 ϵ_a /像素 | 配准模型 | 时间开销/s | |
| Boston | 1712×1368 | 0.47 | PRD | 0.36 | PRD | 43 | 12 |
| Boston Library | 1504×1000 | 0.32 | PRD | 0.32 | PRD | 18 | 6.5 |
| Brain T1-PD | 512×512 | 0.66 | PRD | 0.98 | P | 5 | 8 |
| Brussels | 1712×1368 | 0.45 | PRD | 0.35 | PRD | 34 | 31 |
| Brugge Square | 1712×1368 | 0.87 | PRD | 0.43 | PRD | 369 | 58 |
| Brugge Tower | 1712×1368 | 0.42 | PRD | 0.49 | PRD | 12 | 28 |
| Capital Region | 1712×1368 | 0.73 | PRD | 无 | PRD | 266 | 1225 |
| Dashpoint (2%重叠区) | 2048×1536 | 0.96 | PRD | 0.30 | PRD | 26 | 10 |
| Summer Night-Winter Day | 1504×1000 | 1.09 | PRD | 无 | PRD | 748 | 300 |
| Night-Day (Summer) | 1504×1000 | 0.58 | PRD | 0.62 | PRD | 1094 | 43 |
| Summer-Winter (Day) | 1504×1000 | 0.58 | PRD | 0.60 | PRD | 158 | 51 |
| White Tower | 1504×1000 | 0.67 | PRD | 1.14 | PRD | 192 | 56 |
| Eiffel | 1712×1368 | 0.60 | PRD | 0.30 | PRD | 8 | 22 |
| EO-IR 1 | 300×236 | 1.22 | PRD | 1.59 | PRD | 11 | 107 |
| EO-IR 2 | 676×280 | 0.94 | PRD | 无 | PRD | 16 | 51 |
| Grand Canyon 1 | 1184×780 | 0.89 | PRD | 0.88 | P | 178 | 11 |
| Grand Canyon 2 | 900×568 | 0.51 | PRD | 1.20 | PRD | 15 | 592 |
| Melanoma | 1156×880 | 1.06 | Q | 1.88 | Q | 30 | 126 |
| Retina | 1600×1200 | 1.16 | Q | 0.58 | Q | 383 | 23 |
| Extreme Zoom (×6.4) | 1504×1000 | 1.03 | S | 0.33 | PRD | 4 | 761 |
| Satellite | 2878×2878 | 0.62 | PRD | 0.26 | PRD | 51 | 67 |
| White Board | 1504×1000 | 0.56 | PRD | 0.20 | PRD | 261 | 12 |

注:LPF-ICP使用2.4GHz的英特尔酷睿i7与8GB内存的机器,而GDB-ICP^[9]用3.2GHz的奔腾4与2GB内存的机器;另外,S代表相似变换,P代表射影变换,PRD代表径向透镜像畸变叠加射影变换,而Q代表二次函数变换



图5 用LPF-ICP方法对Rensselaer数据组中22对图像对配准的结果

Fig. 5 Results of registration of 22 pairs of images on Rensselaer data set by using the LPF-ICP method

首先,基于配准判据(15),LPF-ICP方法配准了所有的22对图像(成功率为100%)。对图5进行视觉检查可以看出,经空间变换后源图像与其目标图像能很好地配准。GDB-ICP方法配准了其中的19对(成功率为86%),失败的3对图像为:EO-IR2图对、Summer Night-Winter Day图对和Capital Region图对。另外,基于全体特征点匹配的SIFT方法^[1,9]只配准了22对中的7对(成功率为32%)。通过对比可以看出,LPF-ICP方法在配准成功率上明显占优。

其次,由表3可知,LPF-ICP方法的平均配准误差为0.75像素,而GDB-ICP方法为0.67像素,都为亚像素水平。具体而言,在LPF-ICP方法所完成的22对配准中,77.3%(即17对)的图像对的配准误差低到亚像素级(即小于1像素),剩下

的22.7%(即5对)的误差为像素级(即小于或等于1.22像素)。特别地,对于新增的3对图像配准对,即EO-IR2图对、Summer Night-Winter Day图对和Capital Region图对,其误差分别为0.94像素、1.09像素和0.73像素,与由全体数据获得的统计规律很吻合。而在GDB-ICP方法完成的19对配准中,78.9%的误差低至亚像素级(即15对),其余的21.1%(即4对)的误差为像素级(即小于或等于1.88像素)。两种方法的配准精度相当,进而说明LPF-ICP方法采用的特征点在数量及精度上已能够驱动ICP配准。

最后,由表3可知,LPF-ICP方法完成配准的平均时间开销为178s,而GDB-ICP方法为163s,数值接近。但考虑到本实验使用的是2.4GHz的英特尔酷睿i7与8GB内存的机器,

GDB-ICP 方法^[9]使用的是 3.2GHz 的奔腾 4 与 2GB 内存的机器,因此其可比性不大。

LPF-ICP 方法虽然在配准 Rensselaer 数据组上^[9]取得了成功,但仍存在改进的空间。首先,ICP 配准的收敛范围窄,恰当的初始变换往往是其成功的一个关键因素。上述结果也表明,在配准大射影变换的 Capital Region 图对时,由于简单相似变换不是复杂射影变换的一个好的近似,因此需要用更复杂的仿射变换来初始化。一维匹配^[31]就是一个仿射变换的估算方法,上述实验中也初步证实了其有效性。为了给大畸变图像提供适合的初始变换,仍需进一步探讨 LP 种子点与一维匹配方法的对接方法。另外,在实验中,初始引导区的边长一般是定为 200 像素。然而,也观察到两个例外情况:1)在配准重叠区小的 Dashpoint 图对与 Boston Library 图对时,需要将边长相应缩小;2)在配准光照及焦距变换大的 Extreme Zoom 图对与 Summer Night-Winter Day 图对时,为了应对引导区内稀疏的特征点,需加大边长。为了给各类图像的配准确定适合的初始引导区尺寸,需要进一步研究重叠区尺寸、对应特征点数等因素与引导区尺寸的关系等。

结束语 本研究表明,利用 LPCD 方法能从大形貌畸变图像中提取可靠的 LP 角点。进一步,用匹配的 LP 种子点(包括 LP 角点与泡点)而非 SIFT 特征点为图像配准提供可靠的初始引导区。另外,只采用单尺度特征点(Harris 角点及边点)在原始图像上驱动 ICP 过程,就能实现引导区扩张及其配准模型的升级,直至全图像配准。通过整合上面两种技术,本文提出了一种按 LP 种子长大方式来配准二维图像的新方法。实验评价表明,该方法成功地配准了所有 22 对挑战性图像对,而 GDB-ICP 方法则只完成了其中的 19 对,从而证实了 LPF-ICP 方法的有效性。在今后的研究中,将进一步探索提供初始仿射变换的方法与确定初始引导区尺寸的自适应方法,以扩展适用范围;同时也应减少计算开销,以提高实用性。

参 考 文 献

- [1] BROWN M,LOWE D G. Automatic panoramic image stitching using invariant features [J]. *Int. J. Comput. Vis.*, 2007, 71(1): 59-73.
- [2] DUFAUX F,MOSCHENI F. Motion estimation techniques for digital TV: A review and a new contribution[J]. *Proc. of the IEEE*, 1995, 83(6): 858-876.
- [3] LUCAS B D,KANADE T. An iterative image registration technique with an application to stereo vision [C]// *International Conference on Artificial Intelligence*. Morgan Kaufmann Publishers Inc., 1981: 674-679.
- [4] BROWN L G. A survey of image registration techniques [J]. *ACM Comput. Surv.*, 1992, 24(4): 325-376.
- [5] BAKER S,MATTHEWS I. Lucas-Kanade 20 years on: A unifying framework [J]. *International Journal of Computer Vision*, 2004, 56(3): 221-255.
- [6] HOMBK P,SCHUNCK B G. Determining optical flow [J]. *Artif. Intell.*, 1981, 17(1-3): 185-203.
- [7] MAES F,COLLIGNON A,VANDERMEULEN D, et al. Multi-modality image registration by maximization of mutual information [J]. *IEEE Trans. Med. Imag.*, 1997, 16(2): 87-198.
- [8] VIOLA P, III W M W. Alignment by maximization of mutual information [J]. *International Journal of Computer Vision*, 1997, 24(2): 137-154.
- [9] YANG G, STEWART C V, SOFKA M, et al. Registration of challenging image pairs: initialization, estimation, and decision [J]. *IEEE Trans. on Pattern Anal. and Mach. Intell.*, 2007, 29(11): 1973-1989.
- [10] ZOKAI S,WOLBERG G. Image registration using log-polar mappings for recovery of large-scale similarity and projective transformation [J]. *IEEE Trans. on Image Process.*, 2005, 14(10): 1422-1434.
- [11] LOWE D. Distinctive image features from scale-invariant keypoints [J]. *International Journal of Computer Vision*, 2004, 60(2): 91-110.
- [12] HARRIS C,STEPHENS M. A combined corner and edge detector [C]// *Proc. of 4th Alvey Vision Conference*. Manchester, United Kingdom: 1988: 147-151.
- [13] CANNY J. A computational approach to edge detection [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1986, 8(6): 679-698.
- [14] FAUGERAS O,LUONG Q T,PAPADOPOULOU T. The geometry of multiple images [M]. Cambridge, MA: MIT Press, 2001: 251-255.
- [15] CAN A, STEWART C, ROYSAM B, et al. A feature-based, robust, hierarchical algorithm for registering pairs of images of the curved human retina [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2002, 24(3): 347-364.
- [16] STEWART C, TSAI C L, ROYSAM B. The dual-bootstrap iterative closest point algorithm with application to retinal image registration [J]. *IEEE Trans. on Medical Imaging*, 2003, 22(11): 1379-1394.
- [17] PRESS W H, TEUKOLSKY S A, VETTERLING W T, et al. *Numerical recipes in C: The art of scientific computing* (2nd ed) [M]. Cambridge CB2 1RP: Cambridge University Press, 1992: 683-688.
- [18] TSAI C L, LI C Y, YANG G, et al. The edge-driven dual-bootstrap iterative closest point algorithm for registration of multi-modal fluorescein angiogram sequence [J]. *IEEE Transactions on Medical Imaging*, 2010, 29(3): 636-649.
- [19] YANG S, YANG C L. Image registration algorithm based on sparse random projection and scale-invariant feature transform [J]. *Acta Optica Sinica*, 2014, 34(11): 98-102. (in Chinese)
杨飒,杨春玲. 基于压缩感知与尺度不变特征变换的图像配准算法 [J]. *光学学报*, 2014, 34(11): 98-102.
- [20] XU J J, ZHANG Y, ZHANG H. Fast image registration algorithm based on improved Harris-SIFT descriptor [J]. *Journal of Electronic Measurement and Instrumentation*, 2015, 29(1): 48-54. (in Chinese)
许佳佳,张叶,张赫. 基于改进 Harris-SIFT 算子的快速图像配