

基于迭代的非刚性点阵配准算法

周红玉¹ 杨 扬^{1,2} 张 慷¹

(云南师范大学信息学院 昆明 650092)¹

(西部资源环境地理信息技术教育部工程研究中心 昆明 650092)²

摘 要 提出的非刚性点阵配准算法把一种鲁棒性全局和局部多特征用于对应关系评估,并结合高斯混合模型进行空间变换更新。首先,定义两个距离特征,分别测定两个点阵间的全局和局部几何结构差异,这两个特征形成了一种基于能量优化方程的多特征,通过最小化此多特征,可以灵活地评估点阵间的对应关系。其次,设计一种基于高斯混合模型的空间变换能量方程,同时借助 L_2 距离最小化方法将其最小化,以此改善空间变换更新。最后,采用轮廓配准和图像特征点配准测试了算法的性能,并与其他 4 种先进方法进行了对比,该算法在大部分实验中展现了最好的配准效果。

关键词 非刚性点阵配准,多特征,对应关系评估,高斯混合模型,空间变换更新

中图法分类号 TP391.4 文献标识码 A

Non-rigid Point Set Registration Algorithm Based on Iteration

ZHOU Hong-yu¹ YANG Yang^{1,2} ZHANG Su¹

(School of Information Science and Technology, Yunnan Normal University, Kunming 650092, China)¹

(Western Resources Environment Geographic Information Technology Engineering Research Center of the Ministry of Education, Kunming 650092, China)²

Abstract We proposed a non-rigid point set registration algorithm. It uses a robustly global and local multi-feature for correspondence estimating, and combined with the Gaussian mixture model for transformation updating. Firstly, to measure global and local structural diversities, we introduced two distance features, among two point sets, respectively. Then, the two features formed a multi-feature based cost matrix. It provides a flexible approach to estimate correspondences by minimizing the global or local structural diversities. Finally, we designed a Gaussian mixture model based energy function for refining the transformation updating, and it was minimized by the L_2 distance minimization. By contour registration, sequence and real images, we tested the performance of the algorithm and compared against four state-of-the-art methods. This algorithm shows the best alignments in all most of the experiments.

Keywords Non-rigid point set registration, Multi-feature, Correspondence estimating, Gaussian mixture model, Transformation updating

1 引言

非刚性配准技术作为图像处理的一个重要环节,被广泛应用于计算机视觉、机器学习、医学影像、模式识别以及地理信息系统等诸多领域。它的作用就是把一个点阵(称为源点阵)同另外一个先前发生了形变的点阵(称为目标点阵)进行配准。据文献记录,主要存在两类非刚性点阵配准方法,一种是迭代与非迭代方法,另一种是学习与非学习方法。本文主要基于第一种分类对非刚性点阵配准方法进行介绍和讨论。

非迭代方法是采用单一的评估方式重现两个点阵之间的对应关系,评估使用的是高级结构特征,比如直线、曲线、曲面、ShapeContext 以及图论。在以上提到的这些特征中,

Shape Context 和图论是最受欢迎的两个几何结构特征。运用 Shape Context 和图论特征方法是试图最小化两个点阵之间的点分布差异和图像关联差异来获取对应关系。在处理非刚性点阵配准问题和改善配准性能方面,参数学习法具有重要作用,但最近很少有相关文章发表。

迭代方法主要涉及一个交替的两步过程:(1)对应关系评估;(2)空间变换更新。不同于非迭代方法,迭代方法能够逐渐调整源点阵的几何结构和位置,使源点阵变得更接近于目标点阵,那么两个点阵间的对应关系评估也就随之变得相对简单。为了处理非刚性点阵配准存在的问题,Chui 和 Rangarajan 在匹配算法(TPS-RPM)^[1]中首次引入了这种交替的两步过程,采用了软分配^[2,3]和确定性退火技术^[4,5]进行对应关

周红玉(1988—),女,硕士生,主要研究方向为非刚性点阵配准,E-mail:daydayup-1314@163.com;杨 扬(1980—),男,博士,讲师,主要研究方向为医学图像处理、图像配准、地理信息空间技术、人体咀嚼系统(通信作者);张 慷(1989—),男,硕士生,主要研究方向为图像配准基础算法。

系评估,同时控制基于薄板样条函数^[6]的空间变换更新。Myronenko 等^[7]则提出一种带有一致性约束^[8]的极大似然估计方法,该方法保留点阵的拓扑结构。随后,Myronenko 和 Song^[9](CPD)针对刚性和非刚性配准改进了先前的算法^[7],并运用快速高斯变换^[10]和低秩矩阵近似法^[11]获得高速配准。最近,Jian 和 Vemuri^[12](GMMREG)介绍了一种高斯混合模型方法,他们把对应关系评估看作是两个高斯混合模型(GMM)之间的校正,并通过最小化两个模型间的 L_2 -距离^[13]进行空间变换更新。周志勇等^[14,15]将 GMM 推广为 t 分布混合模型并构造了含局部空间约束性质的 Dirichlet 分布参数来减少异常点和重尾点的影响从而提高算法的鲁棒性。近期,Ma 等^[16,17]先结合 Shape Context 特征建立两个点阵间粗略的对应关系,后基于贝叶斯模型对关系评估进行了改进,并使用一种鲁棒性 L_2E 评估函数^[18]估算空间变换。祝继华等^[19]设计了一种适用于二维/三维点集的高效最近邻搜索法为使用距离特征进行非刚性点阵配准的算法提高最近邻搜索效率。Wang 等^[20]也基于非刚性点阵配准方法描述了一种非对称高斯表示法,即利用非对称高斯模型捕获点阵的非对称空间分布,作为评估两个点阵之间对应关系的一个特征描述组。

本文介绍一种采用多特征和高斯混合模型的鲁棒性非刚性点阵配准算法。本文第 2 节介绍所提算法的主要思想;第 3 节首先评估方法性能,然后与其他先进方法作比较;最后进行讨论总结。

2 方法

设 $\{a_i, i=1,2,\dots,A\}$ 和 $\{b_j, j=1,2,\dots,B\}$, 定义在 R^2 或者 R^3 数据空间下,分别作为源点阵 a 和目标点阵 b 。本文所提方法的主要过程分为:(1)在每次迭代中使用形变模板 a^w (初始 $a^w=a$) 评估 a 在 b 中的当前对应 b^c ;(2)根据重现的 a 和 b^c 之间的对应关系更新形变模板 a^w 的位置信息。通过迭代这两个过程,形变模板 a^w 将逐步连续地接近目标点阵 b ,最终与它们在 b 中的真实对应点匹配。

2.1 基于多特征的对应关系评估

在第一步中,基于能量函数,最小化多特征,评估每次迭代过程中的对应点 b^c ,能量函数表示为

$$E(M) = \sum_i^A \sum_j^B M_{ij} C_{a_i^w b_j} \quad (1)$$

其中,解 M 是 a^w 和 b 的二进制对应关系矩阵,满足 $\sum_j^B M_{ij} = 1, i \in 1, \dots, A$, 并且 $M_{ij} \in 0, 1$ 。 $C_{a_i^w b_j}$ 表示混合特征能量优化矩阵,定义方程为

$$C_{a_i^w b_j} = G_{a_i^w b_j} + \alpha L_{a_i^w b_j} \quad (2)$$

其中, α 是一个加权参数,控制 $G_{a_i^w b_j}$ 和 $L_{a_i^w b_j}$ 的平衡, α 的值通过一个线性退火计划 $T = T \cdot h$ 逐渐减小。 $G_{a_i^w b_j}$ 是一个全局特征差异矩阵,定义为

$$G_{a_i^w b_j} = \|a_i^w - b_j\|^2 \quad (3)$$

它描述点阵 a^w 和 b 之间的全局几何结构差异,并且被一种线性分配解决方案最小化。局部特征差异矩阵 $L_{a_i^w b_j}$ 则被定义为

$$L_{a_i^w b_j} = \sum_{p=1}^P \|T(N(a_i^w)_p, b_j) - N(b_j)_p\|^2 \quad (4)$$

它描述点阵 a^w 和 b 之间的局部几何结构差异,同样被一种线性分配解决方案最小化。其中, P 代表相邻点的数量, $N(a_i^w)_p$ 和 $N(b_j)_p$ 分别表示 a^w 和 b 的第 P 个最近点, P 对保留拓扑结构和局部相似性测定起着一样重要的作用,同时处理噪音、冗余、旋转和缺失点。 T 是平移函数,表示为

$$T(N(a_i^w)_p, b_j) = N(a_i^w)_p + (b_j - a_i^w) \quad (5)$$

为了最小化 $C_{a_i^w b_j}$, 我们采用一种线性分配解决方案,首先给 α 一个较大的初始值,然后通过公式 $\alpha = \alpha \cdot T$ 逐渐减小其值,能量最小化相当于最小化局部特征差异 $L_{a_i^w b_j}$, 随 α 逐渐变小,处理过程则趋向于最小化全局几何结构特征差异 $G_{a_i^w b_j}$ 。因此,我们能够通过最小化两个点阵之间的全局或者局部特征差异灵活地评估对应关系。

把式(2)看作一种线性分配问题来处理。Jonker-Volgenant 算法^[21]以牺牲时间代价 $O(N^3)$ 给我们提供最短的增广路径,配准之前我们把 $C_{a_i^w b_j}$ 标准化为 $(0, 1)$ 矩阵,为了满足该算法的限制条件,使用 $\lfloor C_{a_i^w b_j} \times R \rfloor$ 对计算出的 $C_{a_i^w b_j}$ 进行数值处理,其中 R 是一个值较大的解空间,设为 10^6 。同时,当 $C_{a_i^w b_j}$ 不是方阵时,通过分配虚拟条目^[22]把 $C_{a_i^w b_j}$ 转换成方阵。解出的 M 保证了从 a^w 到 b 的一一对应关系。最后更新 a 的当前对应点 b^c ,公式为:

$$b^c = M \cdot b \quad (6)$$

2.2 基于高斯混合模型的空间变换更新

在第二步中,利用一种基于高斯混合模型的空间变换更新 a^w 的位置,模型定义为

$$E_{L_2}(\theta) = \int f(a | \theta)^2 dx - \frac{2}{n} \sum_{i=1}^n f(x_i | \theta) \quad (7)$$

其中, θ 是为了最小化上述标准而由 $f(x_i | \theta)$ 引入的一个参数。 $-f(x_i | \theta)$ 代表对低概率点 x_i 的补偿,比最大似然估计给出的补偿 $-\log f(x_i | \theta)$ 的执行效果更好。

现在回到空间变换更新的推导。设 $S = \{(a_i, b_i)\}_{i=1}^n$ 表示点对应关系集合, f 变换定义为 $b_i^c = f(a_i)$, 且需要进行估计以拟合内点。因为将 L_2 距离应用到多元正态分布中,那么处理球形的协方差矩阵 Σ 时,只需要简单的设置,即把 Σ 转换成 Λ :

$$\phi(b_i^c - f(a_i)) \sim N(0, \Sigma) \sim N\left(\begin{bmatrix} 0_{11} \\ \vdots \\ 0_{n1} \end{bmatrix}, \begin{bmatrix} \sigma_1^2 & & \\ & \ddots & \\ & & \sigma_n^2 \end{bmatrix}\right) \sim N(0, \Lambda) \quad (8)$$

其中, $|\Lambda| = \sigma_1^2 \cdot \sigma_2^2 \cdot \dots \cdot \sigma_n^2 = \sigma^{2n}$, 而且一种对冗余不太敏感的估计函数在处理点对应关系集合 S 方面起到相对较好的作用。假设内点受到正态分布所带来的噪音的影响,采用 L_2 最小化方法评估我们的能量函数,如下所示:

$$E_{L_2}(f, \Lambda) = \frac{1}{2^d \pi^{\frac{d}{2}} |\Lambda|^{\frac{d}{4n}}} - \frac{2}{n} \sum_{i=1}^n \phi(b_i^c - f(a_i) | 0, \Lambda) \quad (9)$$

其中, f 是非刚性变换的需求。然后,在一个泛函空间对变换进行建模,该空间称为再生核希尔伯特空间($\{RKHS\}$)^[23,24]。在此,简单回顾一下再生核希尔伯特空间的基本原理,设 H 为一个再生核希尔伯特空间,由正定矩阵价值内核 $\Gamma: R^d \times R^d \rightarrow R^{d \times d}$ 定义, d 表示数据的维数。使用 $f(a) = \sum_{i=1}^n \Gamma(a, a_i)$

c_i ^[24,25]代表最理想的变换 f 。其中系数 c_i 是一个 $d \times 1$ 的一维向量。这样,在无限维数的希尔伯特空间上,最小化问题变得简单化,便于寻求 n 个系数 c_i 的有限集。为了避免重要计算的复杂度,采用稀疏逼近方法^[26],即随机地选择一个大小为 k 个输入点的子集 $\{\bar{a}_i\}_{i=1}^k$ 。因此,试图找到这样一种形式的解:

$$f(a) = \sum_{i=1}^k \Gamma(a, \bar{a}_i) c_i \quad (10)$$

然后,加上正则项,以增加变换的光滑性约束。扩展形式如下:

$$E_{L_2}(f, \Lambda) = \frac{1}{2^d \pi^{\frac{d}{2}} |\Lambda|^{\frac{dn}{d}}} - \frac{2}{n} (\sqrt{(2\pi)^d |\Lambda|^{\frac{d}{n}}})^{-1} \sum_{i=1}^n \exp\{-\|b_i - \sum_{j=1}^k \Gamma(a_i, \bar{a}_j) c_j\|^2 (2|\Lambda|^{\frac{1}{n}})^{-1}\} + \lambda \|f\|_F^2 \quad (11)$$

其中, λ 是一个正则常数,决定公式中 3 项的取舍, $\|f\|_F^2$ 起到稳定的作用,基于对角可分解内核^[25]: $\Gamma(a_i, a_j) = \exp\{-\beta \|a_i - a_j\|^2\} I$ 中的参数 β 控制着两个点阵相互作用范围的宽度。能量函数(11)可被转换为如下形式:

$$E_{L_2}(f, \Lambda) = \frac{1}{2^d \pi^{\frac{d}{2}} |\Lambda|^{\frac{dn}{d}}} - \frac{2}{n} (\sqrt{(2\pi)^2 |\Lambda|^{\frac{d}{n}}})^{-1} \sum_{i=1}^n \exp\{-\|b_i^T - U_i \cdot C\|^2 (2|\Lambda|^{\frac{1}{n}})^{-1}\} + \lambda \text{tr}(C^T \Gamma C) \quad (12)$$

其中, Gram 矩阵 $\Gamma_{ij} = \Gamma(\bar{a}_i, \bar{a}_j) = \exp\{-\beta \|\bar{a}_i, \bar{a}_j\|^2\}$, $\Gamma \in \mathbb{R}^{k \times k}$ 以及

$$U_{ij} = \Gamma(a_i, \bar{a}_j) = \exp\{-\beta \|a_i, \bar{a}_j\|^2\}, U \in \mathbb{R}^{n \times k} \quad (13)$$

U_i 表示矩阵 U 的第 i 行, 还有关联系数矩阵

$$C = (c_1, \dots, c_k)^T \quad (14)$$

是一个 $k \times d$ 的矩阵, $\text{tr}(\cdot)$ 表示迹。另外,关联系数矩阵 C 所对应的能量函数 E_{L_2} 的导数是空间变换更新过程中所需要的另一个必要条件。给出它的形式:

$$\frac{\partial E_{L_2}}{\partial C} = \frac{2U^T [V \circ (W \otimes \mathbf{1}_{1 \times d})]}{n |\Lambda|^{\frac{2+d}{2n}} (2\pi)^{d/2}} + 2\lambda \Gamma C \quad (15)$$

其中, $V = UC - b^c$ 和 $b^c = (b_1^c, b_2^c, \dots, b_k^c)^T$ 是 $k \times d$ 矩阵, $W = \exp\{\text{diag}(VV^T)/2|\Lambda|^{\frac{1}{n}}\}$ 是 $K \times a$ 维向量, $\text{diag}(\cdot)$ 是对角矩阵, $\mathbf{1}_{1 \times d}$ 是 $1 \times d$ 行向量, \circ 表示 Hadamard 乘积, \otimes 表示 Kronecker 乘积。

利用上面的导数(15)采取拟牛顿方法解决优化问题。考虑能量函数(11)的凸函数特性,使用另外一种确定性退火技术处理内围层噪音参数 σ^2 , 这样结合式(13)、式(14)可以得到 V_{new} 和 b^c , 然后更新形变模板 a^w 的新位置:

$$a^w = V_{new} = UC - b^c$$

最后,回到第一步,继续配准过程,重复这两步过程直到达到退火计划的 T_{final} 结束。

2.3 退火算法

确定性退火技术被广泛应用,它能够有效处理复杂的组合优化问题。在此,进一步给出本文中用到的两个退火计划的详细说明。

在对应关系评估步骤中,需要处理一个退火参数 T , 始于

一个较高温值 T_{init} , 止于一个较低的温度值 T_{final} 。设 h 为退火率,根据公式 $T = T \cdot h$ 逐渐减小 T 值,令 $\alpha = \alpha_{init} \cdot T$, 那么主要控制 C_b 中全局和局部特征差异平衡的加权参数 α 的值也随之逐渐减小。例如, α 的值越大, a^w 和 b 点阵间的局部特征对应关系就越好。随着最小化局部特征能量函数,形变模板 a^w 的拓扑结构被保留,同时解决了由噪音、冗余、循环和缺失点所引发的问题。进而,根据改善的对应关系评估更好地更新 E_{L_2} 空间变换。

在变换评估步骤中,另一个退火参数 σ^2 有待处理,这次采用拟牛顿方法。同样让 σ^2 也始于一个较大的初始值,设 γ^2 为退火率,根据公式 $\sigma^2 = \gamma \cdot \sigma^2$ 逐渐减小 σ 的值。当参数 σ^2 值较大时,式(11)将凸显于一个较大的区域。随着渐变,便可以得到全局最小值,并且全局最小值的位置在 σ^2 值减小过程中平稳改变。我们把先前的全局最小值设为初始值,然后通过拟牛顿方法对它进行迭代,最后,找到一个期望的全局最小值。

总而言之,配准过程中,取每次迭代产生的 E_{L_2} 最小值,使对应关系评估和空间变换更新最终近似全局最优。并且,退火计划为基于全局和局部特征的对应关系评估提供了一种灵活准确的方法,同时也提高了两个步骤的关联性。

2.4 本文算法和参数设置

算法 1 给出了本文所提方法的伪代码。

· 退火参数: 设 T_{init} 等于 a 和 b 之间最大平方距离的 $1/10$, T_{final} 等于 a 中相邻点的均方距离的 $1/8$, $h = 0.7$, $\gamma = 0.5$, $\sigma^2 = 0.05$ 。

· 加权参数: 设等于相邻点数的平方。

· 正则参数: 设等于点阵的长度。

· 相邻点的数量: 初始化为相邻点数最小值, 习惯用于描述局部几何结构。本文设 $p = 5$, 但是为优化某些特定情况, 可以调整 p 值。

· 附加参数: 设决定样本点间相互作用范围宽度的参数, 初始的系数矩阵。

算法 1 基于迭代的非刚性点阵配准

输入: 点阵 a, b

初始化参数 $T_{init}, T_{final}, h, \alpha_{init}, \gamma, \beta, \lambda$, 设置 P , 并确定 $N(a_i)$ 和 $N(b_j)$, 构建 Gram 矩阵 Γ 和 U , 最后初始化 σ^2 和 C_{init}

开始 I_1 : 退火计划

第一步: 结合式(1)、式(6)评估当前的对应 b^c

第二步: 利用渐变式(15)优化能量函数式(12), 采用拟牛顿方法, C 作为初始值

更新: $C \leftarrow \text{minc}\{E_{L_2}(C, \sigma^2)\}$

第三步: 退火 $\sigma^2 = \gamma \cdot \sigma^2$

更新: 通过 $a^w = UC - b^c$ 修正 a^w 的位置

更新: 用公式 $\alpha = T \cdot \alpha = T_{old} \cdot h \cdot \alpha$ 修正参数 α

结束 I_1 : 直到 $T \leq T_{final}$

输出: 最终由式(10)得到 a^w

3 实验

用两个系列实验测试本文提出方法的性能: 轮廓配准 (Contour point sets) 和图像特征点配准 (Feature point sets), 并且与 4 个先进方法 CPD^[27], GMMREG, FGM 以及 Leor-

deanu^[28]进行了对比实验。

3.1 轮廓配准实验

本文选了 Fish1、Fish2、Face2D、Maple、Bird 这 5 个点阵图进行轮廓配准实验对比,目标点阵的生成、误差测量以及性能评估沿用了 CPD 中的方法。

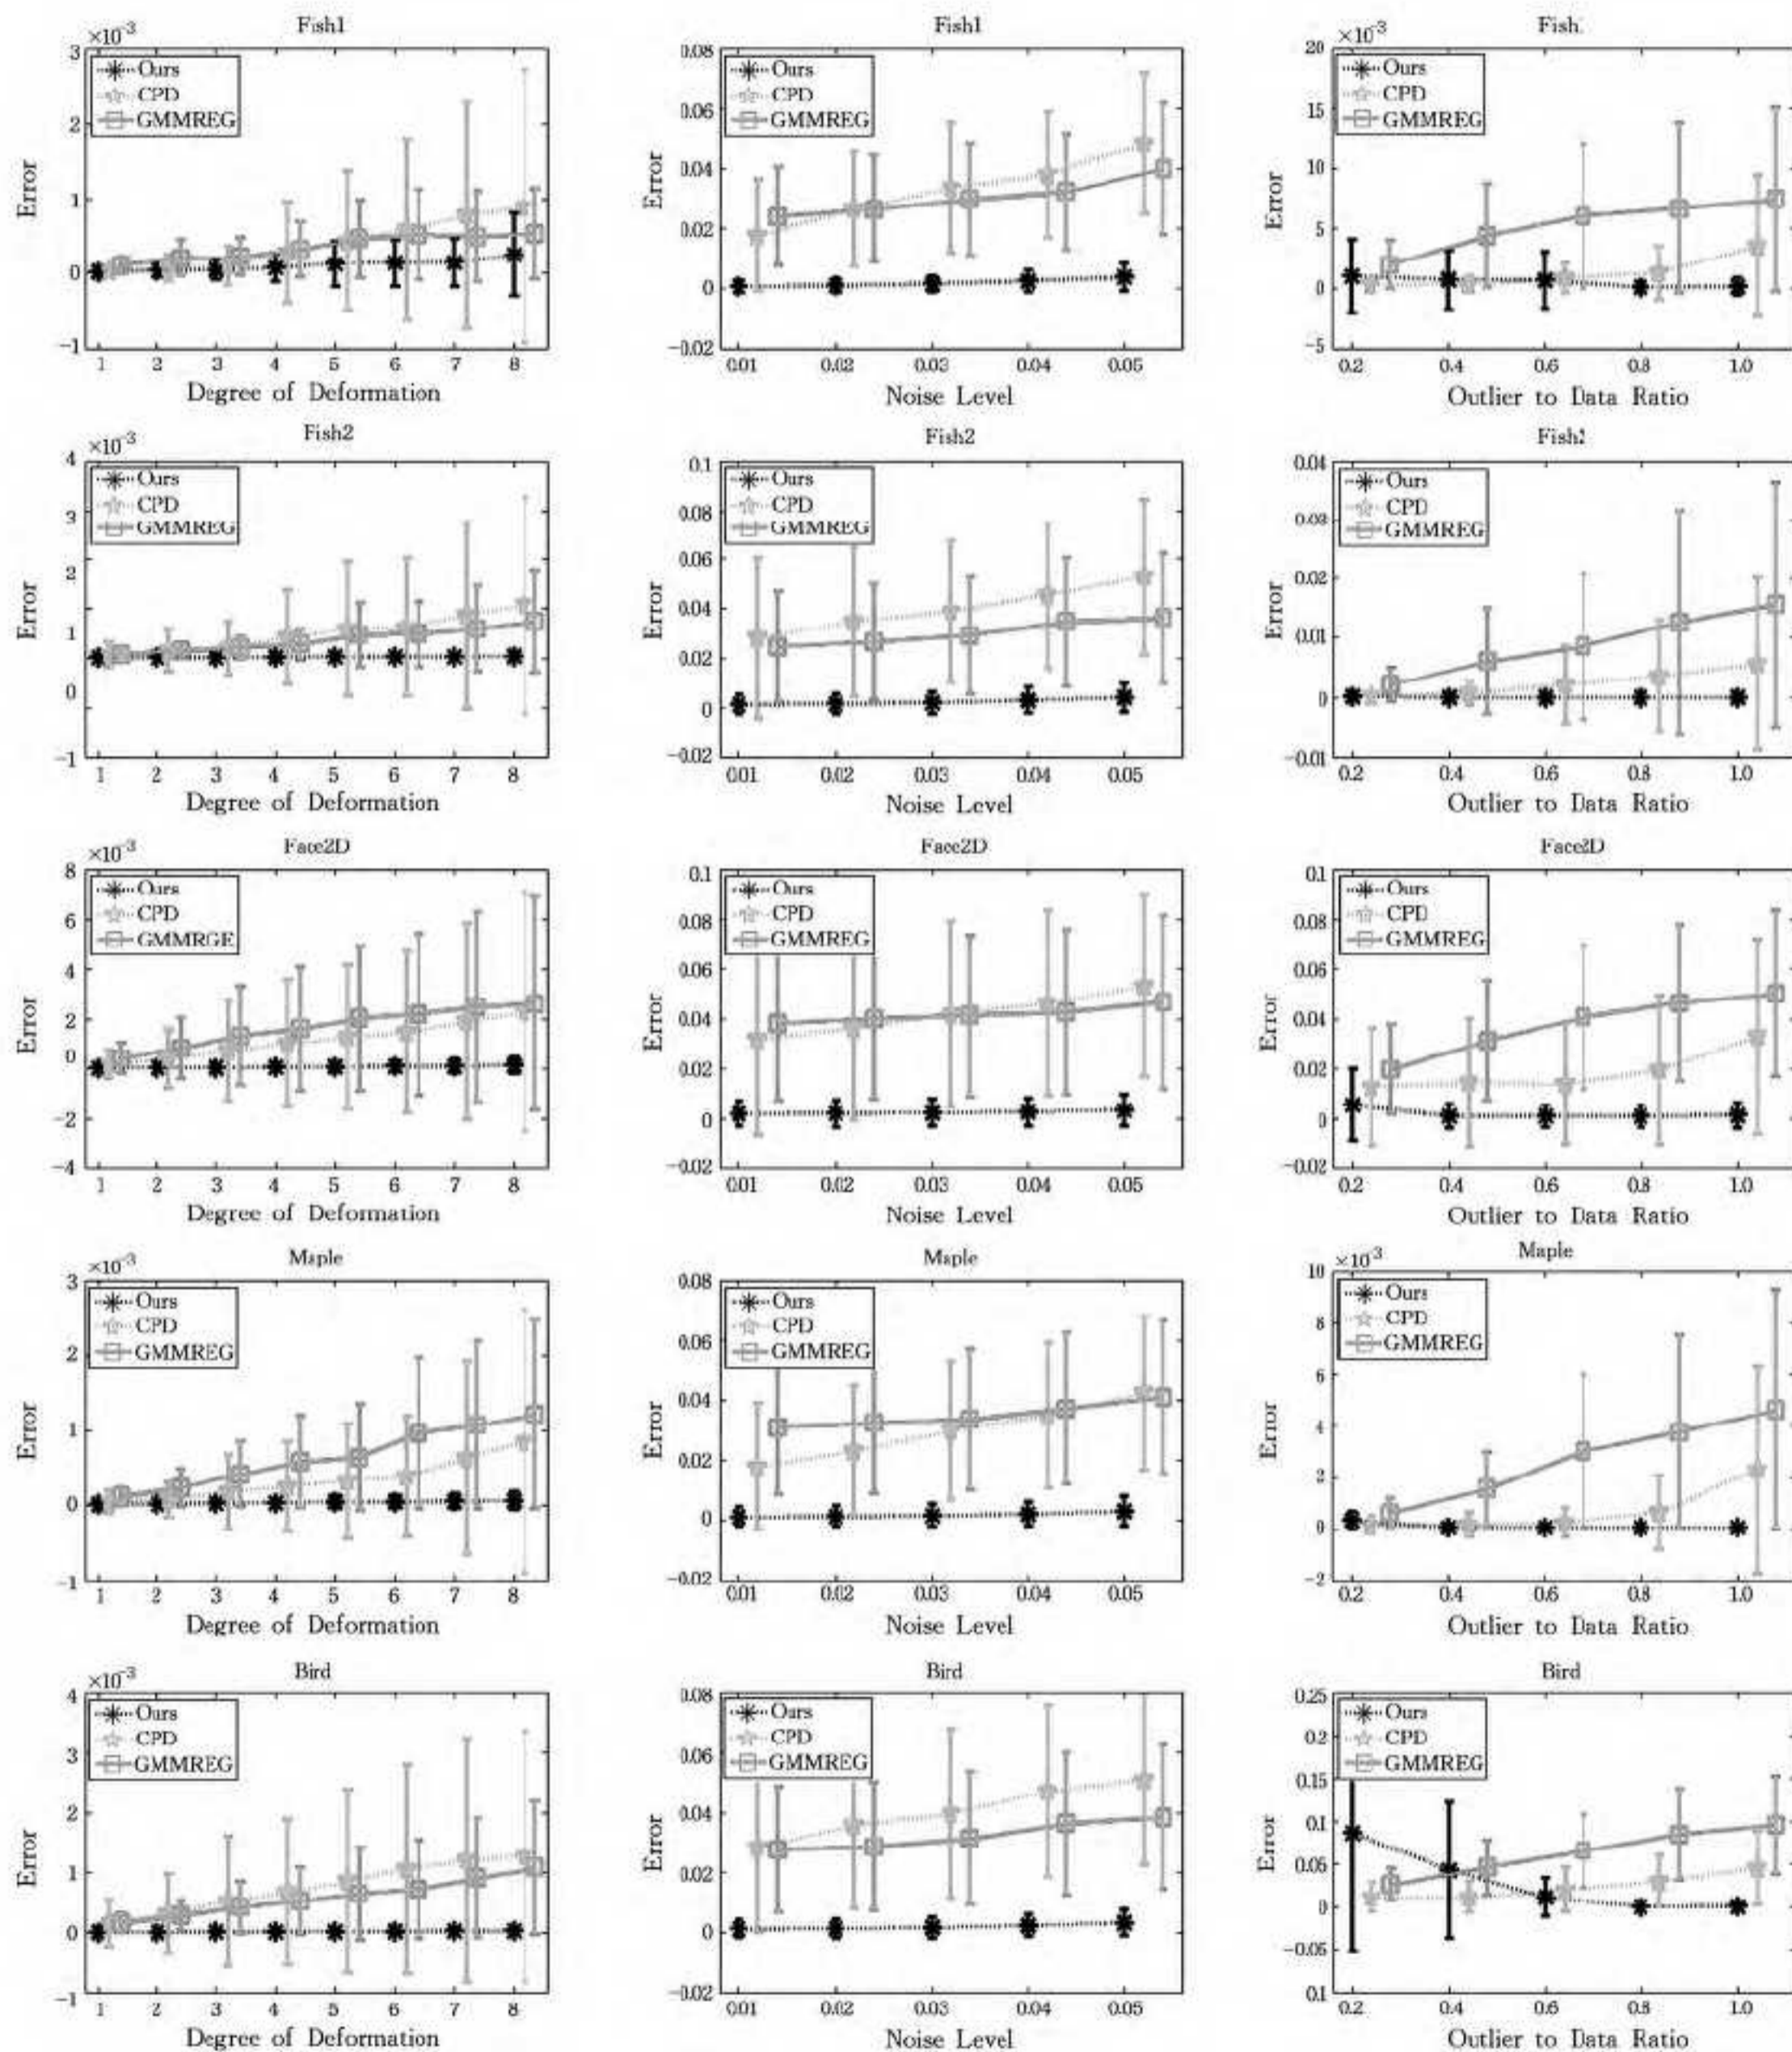
目标点阵,在每个源点阵的边界上设置 8 个控制点,每个控制点有 4 个自由移动方向和 0.2 的移动距离,以便于生成一系列恰当且丰富的形变,每个控制点移动的顺序和方向随机确定。被移动的控制点的数量界定了形变的等级(在二维实例中有 8 个等级),被移动的控制点越多,形变等级越高。在形变基础上构建噪音干扰情况,使用 5 个高斯白噪等级,从 0.01 到 0.05。存在数据冗余情境实验则使用 5 个数据冗余

比率,从 0.2 到 1。

误差测量,为了直接公平的比较,沿用 CPD 的误差测量方法,本文中误差测量为形变模板与实际对应点阵之间的均方距离。

性能评估,使用平均误差比较这些方法的性能,每个设置(包括形变程度、噪音等级、数据冗余)都进行 50 次随机重复实验。

从 Fish1、Fish2、Face2D、Maple、Bird 5 个点阵的轮廓配准结果上对所提方法进行性能评估,点阵通常具有较高的抽样率和更为复杂的局部相似性。下面根据上述 5 个点阵在不同方法下的轮廓配准实验结果,分别从形变、噪音、冗余 3 种情况进行对比分析,图 1 是误差曲线图。




误差线表明了 50 个随机实验下的平均误差和标准偏差

图 1 本文方法(*)、CPD(☆)、GMMREG(□)方法在 5 个点阵配准上的实验性能比较

形变实验,图 1 中第一列分别给出了上述 5 个点阵在 8 个形变等级下的轮廓配准实验误差结果,每个点阵配准都分别采用了本文方法、CPD 以及 GMMREG 3 种方法,误差线

表明了不同方法各自的性能,包括平均误差和标准偏差。本文方法在所有实验中给出了精确的配准结果,并在所有形变等级中给出了最好的性能。随着形变等级升高, Fish1、

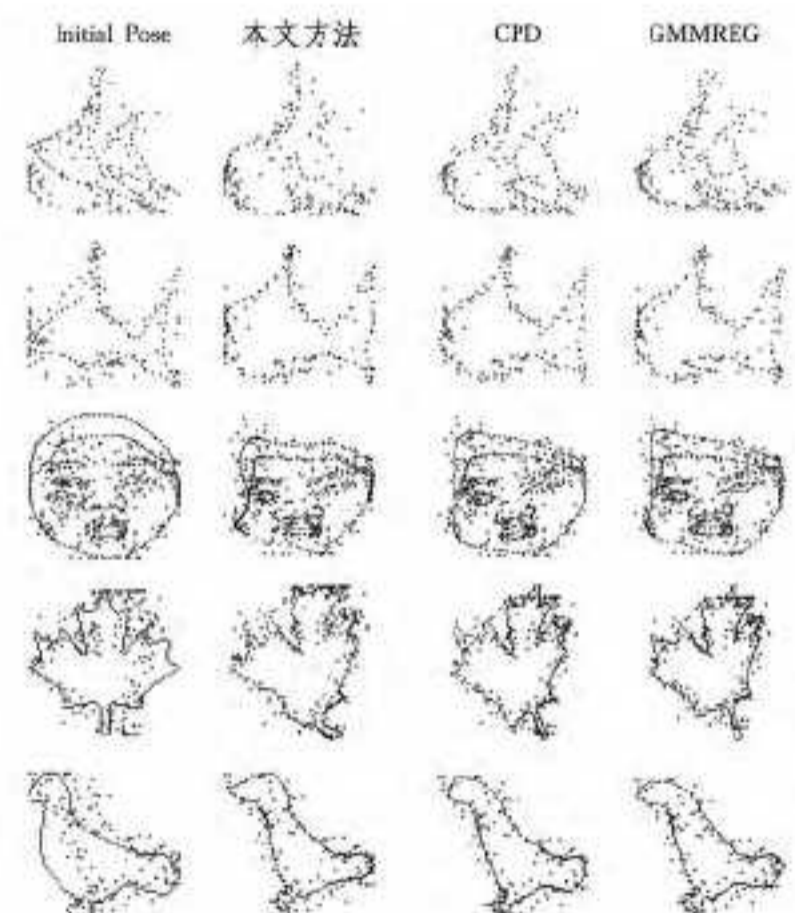
Fish2、Face2D、Maple、Bird 的配准均保持误差最小,且性能最稳定。图 2 给出了形变实验配准实例。



按行从上到下分别为 Fish1、Fish2、Face2D、Maple、Bird

图 2 形变实验配准模式和配准实例

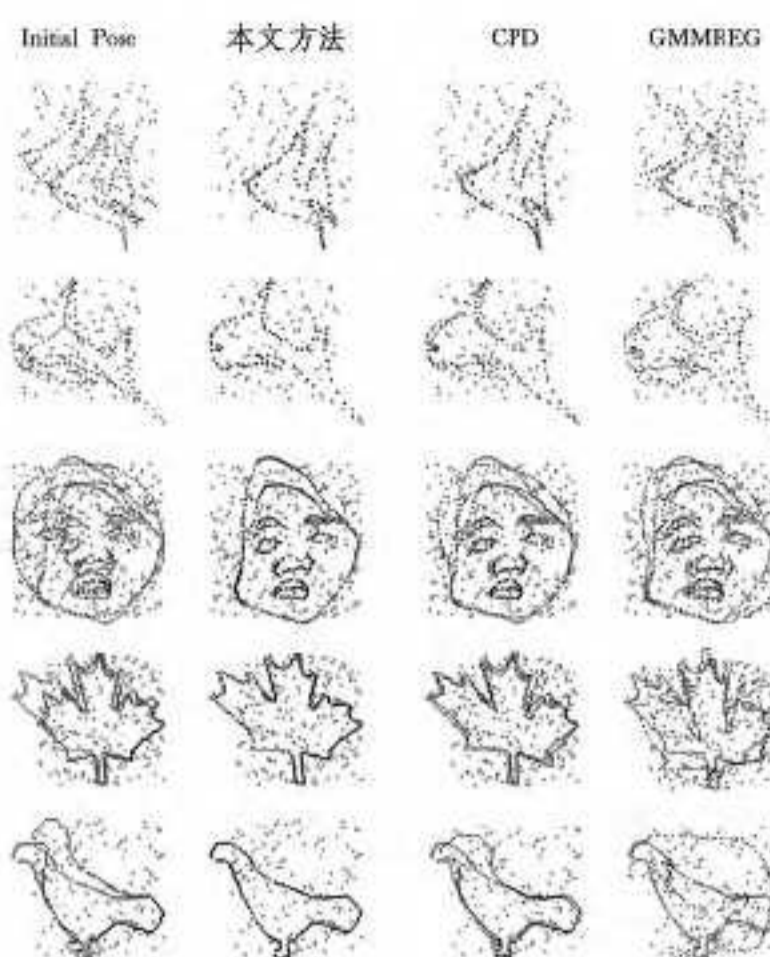
· 噪音干扰:图 1 中第二列分别给出了上述 5 个点阵在 5 个噪音等级干扰情况下的轮廓配准实验误差结果,每个点阵配准都分别采用了本文方法、CPD 以及 GMMREG 3 种方法,误差线表明了不同方法各自的性能,包括平均误差和标准偏差。由图可知,本文方法的误差线在整体上比 CPD、GMMREG 都低很多,并且随着噪音干扰强度增加,在 5 个点阵上的实验中都表现出持续稳定的配准性能。图 3 给出了噪音干扰情况下的配准实例。



按行从上到下分别为 Fish1、Fish2、Face2D、Maple、Bird

图 3 噪音干扰配准模式和配准实例

· 数据冗余:图 1 中第三列分别给出了上述 5 个点阵在 5 个数据冗余等级情况下的轮廓配准实验误差结果,每个点阵配准都分别采用了本文方法、CPD 以及 GMMREG 3 种方法,误差线表明了不同方法各自的性能,包括平均误差和标准偏差。在 Fish2、Face2D、Maple 3 个点阵配准实验中,所提方法效果最好。在数据冗余较小时,Fish1 的轮廓配准误差比 CPD 略高,Bird 的配准性能稳定性也不如 CPD 和 GMMREG。但是,当数据冗余逐渐增大,本文方法配准误差则随之越来越小,性能趋于稳定。即 Fish1 和 Bird 的轮廓配准实验结果表明,在数据冗余较大时,所提方法性能最好。图 4 给出了存在数据冗余时的配准实例。



按行从上到下分别为 Fish1、Fish2、Face2D、Maple、Bird

图 4 数据冗余配准模式和配准实例

3.2 图像特征点配准实验

在第二个系列实验中,分别对系列图像(CMU Hotel and House sequence)和实景图(Pascal 2007 Challenge datasets)进行了配准。

相比于轮廓配准中轮廓点的数量,系列图像配准特征点的数量减少,只是稀疏地分布在图像上。CMU Hotel 和 CMU House 是最受欢迎的系列点集,通常用于测试基于 Graph 的学习算法的性能。Hotel 和 House 数据集分别由 101 和 111 幅图组成,每幅图拥有 30 个特征点。通过实验比较本文方法与 FGM^[27]、Leordeanu^[29]、CPD、GMMREG 4 个方法的性能。图 5 给出了本文方法的配准实例。




图 5 CMU Hotel(上)与 CMU House(下)配准实例

从 Pascal 2007 Challenge 数据集^[29]中挑选了 30 对汽车和 20 对摩托车实景图,通过特征点配准测试,比较本文方法与 FGM^[27]、Leordeanu^[29]、CPD、GMMREG 4 个方法的性能,我们的匹配率明显高于其他 4 种方法。图 6 给出了本文方法的配准实例。表 1 给出了匹配率。




图 6 Pascal 2007 Challenge\quad 汽车和摩托车配准实例

表1 CMU Hotel、CMU House 以及 Car and Motorbike 的匹配率

Method	Parameter Setting	Hotel	House	Car and Motorbike
Ours		99.3%	100%	94.2%
CPD		98.9%	99.6%	79.2%
GMMRE		97.1%	99.5%	82.9%
FGM		—	≈100%	80%
Leordeanu et al ^[29]	S(5) U(5)	94.8% 94.8%	99.8% 99.8%	80% —

结束语 本文介绍了一种新的配准方法,包含了基于多特征的对应关系评估和基于高斯混合模型的空间变换更新,并与其他 4 种先进的方法进行了性能对比,实验表明本文方法展现出最好的效果,特别是在形变和噪音情况下。下面列出了此方法的重要贡献。

· 基于多特征的对应关系评估

我们实施了一种基于多特征的鲁棒性对应关系评估方法,此方法提供了一种更加灵活的方式来评估点阵间的对应关系。

· 基于高斯混合模型的空间变换更新

我们提出了一种基于最小化两个高斯混合模型之间的距离的鲁棒性变换评估函数。

参 考 文 献

[1] Chui H, Rangarajan A. A new algorithm for non-rigid point matching[J]. Computer Vision and Image Understanding, 2003, 89:114-141

[2] Rangarajan A, Chui H, Bookstein F. The softassign procrustes matching algorithm[C]// Information Processing in Medical Imaging (IPMI'97). 1997:29-42

[3] Chui H, Rambo J, Duncan R, et al. Registration of cortical anatomical structures via robust 3dpoint matching[C]// Information Processing in Medical Imaging (IPMI'99). 1999:168-181

[4] Gold S, Rangarajan A, Lu C, et al. New algorithms for 2-d and 3-d point matching: pose estimation and correspondence [J]. Pattern Recognition, 1998, 31:1019-1031

[5] Yuille A. Generalized deformable models statistical physics and matching problems[J]. Neural Computation, 1990, 2:1-24

[6] Bookstein, Fred L. Principal warps: thin-plate splines and the decomposition of deformations[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1989, 11(6):567-585

[7] Myronenko A, Song X, Carreira-Perpinan M. Non rigid point set registration: Coherent point drift[J]. Advances in Neural Information Processing Systems, 2010, 32(12):1009-1016

[8] Yuille A, Grzywacz N. A mathematical analysis of the motion coherence theory[J]. International Journal of Computer Vision, 1989, 3:155-175

[9] Myronenko A, Song X. Point set registration: Coherent point drift[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32:2262-2275

[10] Greengard L, Strain J. The fast gauss transform[J]. Journal of Scientific and Statistical Computing, 1991, 12:7994

[11] Markovsky I. Structured low-rank approximation and its appli-

cations[J]. Automatica, 2008, 44:891-909

[12] Jian B, Vemuri B. Robust point set registration using gaussian mixture models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33:1633-1645

[13] Ruschendorf L, Rachev S. A characterization of random variables with minimum l2 distance [J]. Journal of Multivariate Analysis, 1990, 32:48-54

[14] 周志勇, 薛维琴, 郑健, 等. 基于 t 分布混合模型的点集非刚性配准算法[J]. 光学精密工程, 2013, 21(9):2405-2420

[15] 周志勇, 李莉华, 郑健, 等. 含局部空间约束的 t 分布混合模型的点集配准[J]. 自动化学报, 2014, 40(4):683-696

[16] Ma J, Zhao J, Tian J, et al. Robust estimation of nonrigid transformation for point set registration[C]// IEEE Conference on Computer Vision and Pattern Recognition. 2013, 9:2147-2154

[17] Ma J, Zhou H, Zhao J, et al. Robust Feature Matching for Remote Sensing Image Registration via Locally Linear Transforming[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(12):6469-6481

[18] Scott D. Parametric statistical modeling by minimum integrated square error[J]. Technometrics, 2001, 43:274-285

[19] 祝继华, 尹俊, 邢汶铤, 等. 面向低维点集配准的高效最近邻搜索法[J]. 模式识别与人工智能, 2014(12):1071-1077

[20] Wang G, Wang Z, Chen Y, et al. A robust non-rigid point set registration method based on asymmetric gaussian representation[J]. Computer Vision and Image Understanding, 2015, 141:67-80

[21] Jonker R, Volgenant A. A shortest augmenting path algorithm for dense and sparse linear assignment problems[J]. Computing, 1987, 38:325-340

[22] Miller M, Stone H, Cox I. Optimizing murty's ranked assignment method[J]. IEEE Transactions on Aerospace and Electronic Systems, 1997, 33:851-862

[23] Aronszajn N. Theory of reproducing kernels[J]. Trans. of the American Mathematical Society, 1950, 68:337-404

[24] Micchelli C A, Pontil M. On learning vector-valued function[J]. Neural Computation, 2005, 17:177-204

[25] Zhao J, Ma J, Zhang D. A robust method for vector field learning with application to mismatch removing[C]// CVPR. 2011, vol. 32:2977-2984

[26] Rifkin G Y R, Poggio T. Regularized least-squares classification [J]. In Advances in Learning Theory: Methods, Model and Applications, 2003, 190(1):93-104

[27] Zhou F, De la Torre F. Factorized graph matching [J]. IEEE Conference on Computer Vision and Pattern Recognition, 2012, 23(10):127-134

[28] Leordeanu M, Hebert M. Smoothing-based optimization[J]. International Conference on Computer Vision and Pattern Recognition, 2008, 1988(4):1-8

[29] Leordeanu M, Sukthankar R, Hebert M. Unsupervised learning for graph matching[J]. International Journal of Computer Vision, 2012, 96:28-45