

文章编号 1004-924X(2021)09-2255-13

混合稀疏迭代最近点配准

刘跃生*, 陈新度, 吴 磊, 黄运保, 李海艳
(广东工业大学机电工程学院, 广东 广州 510006)

摘要:为了避免离群值的影响,提出了混合稀疏迭代最近点(SM-ICP)方法,以实现点云精确配准。本文对稀疏表示、正则化求解和点云配准方法进行了研究。首先,利用混合正则项表示配准残差,构建混合稀疏配准函数。然后,结合交替乘法(ADMM)构建了所提出函数的双循环优化框架。其中,混合正则项的平衡权重 θ 可由Sigmoid函数求解;此外,还给出了ADMM优化框架内循环中对应损失函数的标量形式。最后,推导了该标量化损失函数在点云配准中的软阈值表达式。实验结果表明,所提出SM-ICP算法的配准精度优于所对比的算法。特别的,在重叠率约为50%的斯坦福兔子配准实验中,SM-ICP算法的截断配准误差为 2.04×10^{-4} ,较Robust Trimmed-ICP(Tr-ICP)算法和ICP算法的配准误差减小了一个量级,且较稀疏ICP(S-ICP)算法减小了约三倍;在其它对象、场景类型的点云配准实验中,SM-ICP算法的配准精度同样较其它对比算法更优;在具有不同层级随机噪声点云的配准实验中,SM-ICP的截断配准误差为 $4.90 \times 10^{-6} \sim 1.33 \times 10^{-4}$,同样较其它对比算法减小了一个量级或几倍;在发动机叶片配准实验中,本文方法成功实现了点云精确配准,而其它对比算法的配准结果中存在不同程度的点云错位情况。所提出的点云配准方法具有精确、鲁棒性和泛化性等优势。

关键词:点云配准;迭代最近点算法;混合稀疏表示;正则化;交替乘法

doi:10.37188/OPE.20212909.2255

Sparse mixture iterative closest point registration

LIU Yue-sheng*, CHEN Xin-du, WU Lei, HUANG Yun-bao, LI Hai yan

(College of Electromechanical Engineering, Guang Dong University of Technology, ,
Guangzhou 510006, Guangdong)

* Corresponding author, E-mail: 2249791454@qq.com

Abstract: The sparse mixture iterative closest point (SM-ICP) method is proposed for achieving accurate alignment of point-sets, while avoiding the influence of outliers. This study investigates sparse representation, non-convex optimization, and point-sets registration. First, the registered residuals are represented by mixed regularization to establish a sparse mixture formula. The alternating direction of multiplier method (ADMM) is then integrated to solve the proposed formula using a nested framework. Among the variables, the balance weight θ for mixed regularization can be calculated using a sigmoid function. The scalar version is also provided to represent the corresponding loss of function in the inner loop of ADMM. Finally, the soft threshold formula for the scalar version can be deduced in point-set registration. Experimental results indicate that the registration accuracy of the proposed SM-ICP method is better than the that of established algorithms investigated for comparison. This improved accuracy is especially striking in the regis-

收稿日期:2021-03-23;修订日期:2021-05-14.

基金项目:广州市科技计划项目(No. 201902010054);国家自然科学基金(No. 51775116, No. 51975125)

tration experiment of the Stanford bunny dataset. With 50% overlap rate, the trimmed registration error of SM-ICP was 2.04×10^{-4} . Compared with other methods, our trimmed error was one order of magnitude lower than those of the robust Trimmed-ICP (robust Tr-ICP) and ICP algorithms. Moreover, it was approximately three times lower than the error obtained using the sparse ICP (S-ICP) algorithm. In the registration experiments for both other objects and for scene data, the registration accuracy of the SM-ICP method also performed better than comparable algorithms. In the registration experiment of point-sets with different levels of random noise, the trimmed registration error of SM-ICP was $4.90 \times 10^{-6} \sim 1.33 \times 10^{-4}$. This was several times to one order of magnitude lower than those of other algorithms. In the registration experiment for the engine blade, our method successfully achieved accurate registration of point-sets, but the results produced by comparable algorithms displayed different degrees of dislocation in their point-sets registration. In summary, the proposed SM-ICP algorithm displays advantages in accuracy, robustness, and generalization for point-set registration.

Key words: point-set registration; iterative closest point; sparse mixed representation; regularization; alternating direction of multiplier method

1 引言

随着传感器技术的发展,三维激光扫描仪可通过点云感知实体的完整几何信息,在现代工业中占据了重要地位。然而,受遮挡、扫描位姿等因素影响,多视角点云数据在同一坐标下通常是错位且部分重叠的。因此,为了获取完整的三维点云模型,点云配准^[1]旨在搜索相邻视角点云的正确匹配点对,并求解对应的空间变换矩阵。在此基础上,点云配准可将源点云和目标点云配准到相同坐标系下,广泛应用于机器人制造^[2],空间重构^[3]和医学诊断^[4]等领域。

早在 1992 年,Besl 等^[5]提出的 ICP 算法就已被认为是强有力的点云配准方法,其原理简单但富有成效,可简单概括为:迭代匹配最近邻点,并同时更新对应的空间变换矩阵,直到收敛。然而,在部分重叠点云配准中,离群值通常指待配准点云的非重叠部分点集,其由于缺乏有效的匹配点对,会使点云配准问题转化成为更具挑战性的非凸优化问题^[6],以至于 ICP 算法在该类配准中容易陷入局部最优解。

针对离群值问题,为了提高点云配准的稳健性,在经典 ICP 算法的基础上,学者提出了一系列的 ICP 变种方法。其中,Chetverikov 等^[7-8]提出了 Tr-ICP 算法,通过计算迭代过程中的最近邻

匹配点对的欧式距离,并利用截断最小二乘技术惩罚离群值,可有效实现多视角点云配准,但其难以自主调整截断能量函数的内参。

为了进一步避免离群值对配准算法的影响,Bouaziz 等^[6]在 $l_p(p \in [0, 1])$ 正则化稀疏诱导理论的基础上,提出了更具弹性的稀疏迭代最近点(S-ICP)算法,其结合 ADMM 方法构建了双循环的优化框架,并通过计算配准残差的对偶解,有效的实现了点云的精确配准,但 S-ICP 算法受限于单一的 p 阶次正则项,泛化性较差。

另一方面,区别于迭代最近点配准方法,主成分分析法^[9]由于具有良好的特征降维能力,可提取点云的特征线^[10],并实现点云粗配准。此外,基于深度学习的点云配准方法^[11-13]由于具有高效、精确的优势,也得到了广泛的研究,但受限于复杂的数据集、采样方法和超参数优化,其在实际应用中还不够成熟。

由于 ICP 算法的原理具有简单、实用和收敛等优势,且 S-ICP 算法继承了 ICP 杰出的结构并具有良好的离群值惩罚能力。因此,为了解决点云的配准问题,本文在 S-ICP 的基础上,结合了 Li 等^[14-15]和 Stephen 等^[16]所提出的泛化稀疏表示理论,进一步研究了更泛化的混合稀疏 ICP 点云配准方法,以避免离群值的影响,并实现点云精确配准。

2 基本原理

2.1 混合稀疏配准函数

给定源点云 $X = \{x_i, i = 1, 2, \dots, n\}$ 和目标点云 $Y = \{y_j, j = 1, 2, \dots, m\}$, 其中 $x_i, y_j \in \mathbb{R}^3$ 代表三维点坐标。为了避免离群值的影响, S-ICP 提出了利用 p 阶次正则项表示点云配准残差, 以提高点云配准的鲁棒性。然而, 部分重叠点云配准问题本质上是 l_0 范数优化问题, 其优化目标不仅要求配准残差和最小, 也要求匹配的点对最多 (例如 $0+0+0+0+0=0$ 优于 $0+0+0=0$), 如图 1 所示。




图 1 部分重叠点云配准的示意图

Fig. 1 Diagram of partial overlap point-sets registration

因此, 本文在 S-ICP 的基础上, 提出了加权的混合正则项, 以更泛化的表示配准残差 z_i 。进一步的, 点云 X 向 Y 配准的混合稀疏配准函数, 可表示为:

$$\arg \min_{R,t} \sum_{i=1}^n \left[\theta_i \|z_i\|_2^p + (1 - \theta_i) \|z_i\|_2^2 \right], \quad (1)$$

其中, $\theta_i \in [0, 1]$ 表示混合正则项的平衡权重。配准残差 z_i 可表示为

$$z_i = Rx_i + t - y_i, \quad (2)$$

其中, R, t 分别表示旋转矩阵和平移向量, $y_i \in Y$ 是目标点云 Y 相对于源点云 X 的最近邻点, 可表示:

$$y_i = \arg \min \|x_i - y_j\|_2. \quad (3)$$

然而, 由于公式(1)是非光滑、非凸的, 且其对 z_i 求偏导数所得到的 $\|z_i\|_2^{p-1}$ 项, 会在 $\|z_i\|_2 = 0$ 时, 趋于无穷大, 传统的凸优化方法难以对其进行求解。

2.2 交替乘法

为了解该配准函数, 本文结合著名的 ICP 两步法和交替乘法, 构建了双循环的优化框架。其中外循环可利用式(3)搜索最近邻点作为迭代过程中的估计匹配点, 内循环则由交替乘法将式(1)对偶分解为:

$$\arg \min_{z_i} \sum_{i=1}^n \left[\theta_i \|z_i\|_2^p + (1 - \theta_i) \|z_i\|_2^2 + \frac{\mu}{2} \|z_i - h_i\|_2^2 \right], \quad (4)$$

$$\arg \min_{R,t} \sum_{i=1}^n \|Rx_i + t - c_i\|_2^2, \quad (5)$$

$$\lambda_i = \lambda_i + \mu \delta_i, \quad (6)$$

其中: λ_i 表示拉格朗日乘子, μ 表示惩罚权重, 向量 h_i, c_i 和 δ_i 可分别表示为:

$$h_i = Rx_i + t - y_i + \frac{\lambda_i}{\mu}, \quad (7)$$

$$c_i = y_i + z_i - \frac{\lambda_i}{\mu}, \quad (8)$$

$$\delta_i = Rx_i + t - y_i - z_i, \quad (9)$$

其中: 式(7)和式(8)分别用于描述配准过程源点云和目标点云中匹配点的对偶解。在式(9)的约束下, ADMM 的对偶优化框架将在多次迭代后收敛。

3 正则化损失函数最小化

3.1 平衡权重确定

针对式(5)的求解问题, 可结合 ICP 算法求解对应的空间变换矩阵。然而, 式(4)所涉及的正则化问题依然涉及了平衡权重 θ_i 和 $\|z_i\|_2^p$ 正则项, 难以直接求解。为了有效、快速的求解公式(4), 本文区别于传统的交叉验证方法, 先验的认为源点云在配准算法的作用下, 会收敛于正确的配准位置, 即点云重叠部分的最近邻点对的欧式距离会越来越小。因此, 对于距离较大的最近邻匹配点, 归类于离群值的概率更大, 可设置较大的平衡权重 θ_i , 以充分发挥 p 阶次正则项的稀疏惩罚能力; 反之, 对于距离较小的最近邻匹配点, 可设置较小的平衡权重 θ_i , 以充分发挥 l_2 正则项的最小二乘逼近能力。在此基础上, 本文结合 Sigmoid 函数构建了平衡权重与最近邻点对距离

的关联函数:

$$\theta_i = \frac{1}{1 + \exp(-\eta_i)}, \quad (10)$$

其中, $\eta_i \in [-5, upper]$, $upper$ 是 Sigmoid 函数的可变区间上界, 如图 2 所示。




图 2 不同中位数的 Sigmoid 函数

Fig. 2 Sigmoid function with different median

然后, 对最近邻匹配点对的欧式距离排序并计算其中的中位数 Median。变量 η_i 可定义为:

$$\eta_i = -5 + \|z_i\|_2 \frac{5}{\text{Median}}. \quad (11)$$

为了充分惩罚、弱化离群值, 混合稀疏配准的稀疏性应随着迭代次数的增加而逐渐增强, 即在点云配准过程中, Median 只在初次迭代时计算以作为初始值, 并在每次迭代过程中逐渐减小为上一次迭代的 ν 倍。随着中位数 Median 的逐渐变小, Sigmoid 函数的区间上界 $upper$ 将逐渐变大, 即混合稀疏配准模型中的平衡权重 θ_i 将趋于 1。

3.2 正则化函数标量化

由于公式(4)中的变量 z_i 为向量形式, 求解较为困难。因此, 我们在平衡权重确定的基础上, 利用著名的最优化-最小化框架 (Majorization-Minimization, MM)^[17] 对该优化问题进行标量化处理, 得到更简单的代理模型, 如图 3 所示。




图 3 最优化-最小化算法的框架

Fig. 3 Framework of MM algorithm

首先, 令原函数为

$$f(z_i) = \theta_i \|z_i\|_2^p + (1 - \theta_i) \|z_i\|_2^2 + \frac{\mu}{2} \|z_i - h_i\|_2^2. \quad (12)$$

由 MM 算法可知, 为了构建标量化的代理函数 $f(ah_i)$, 并使得最优解等价于 $z_i = ah_i$, 需证明不等式 $f(ah_i) \leq f(z_i)$ 恒成立。由 S-ICP^[6] 附录 D 知, $\|z_i\|_2^p \geq \|ah_i\|_2^p$ 及 $\|z_i - h_i\|_2^2 \geq \|ah_i - h_i\|_2^2$ 已得到证明。因此, 本文只需证明 $\|z_i\|_2^2 \geq \|ah_i\|_2^2$, 即可得 $f(ah_i) \leq f(z_i)$ 恒成立。假设向量 $H \in R^3$ 与 z_i 正交, 则残差变量 z_i 可表示为:

$$z_i = ah_i + H. \quad (13)$$

对其求平方, 可得:

$$\|z_i\|_2^2 = (ah_i + H)^T (ah_i + H) = \|ah_i\|_2^2 + \|H\|_2^2 \geq \|ah_i\|_2^2. \quad (14)$$

由于 $\|H\|_2^2 \geq 0$, 则可证明 $\|z_i\|_2^2 \geq \|ah_i\|_2^2$, 所以 $f(ah_i) \leq f(z_i)$ 恒成立。在此基础上, 式(4)可转化为标量化的代理函数:

$$\arg \min_{a_i} \sum_{i=1}^n \theta_i \|a_i h_i\|_2^p + (1 - \theta_i) \|a_i h_i\|_2^2 + \frac{\mu}{2} \|a_i h_i - h_i\|_2^2. \quad (15)$$

3.3 l_p 优化方法

为了求解公式(15), 分别求标量参数 a_i 的偏

导数 $\frac{\partial f(a_i)}{\partial a_i}$, 可得:

$$\varphi(a_i) = \theta_i p \|a_i\|_2^{p-1} \|h_i\|_2^p + 2(1 - \theta_i) a_i \|h_i\|_2^2 + \mu(a_i - 1) \|h_i\|_2^2. \quad (16)$$

令 $\varphi(a_i) = 0$, 则公式(16)两边同时除以 $\mu \|h_i\|_2$, 可得:

$$\left(1 + \frac{2(1 - \theta_i)}{\mu}\right) \|a_i h_i\|_2 + \frac{\theta_i p}{\mu} \|a_i h_i\|_2^{p-1} = \|h_i\|_2. \quad (17)$$

令等式(17)左边为 $\psi(a_i h_i)$, 并对其求二阶偏导数。由于 $\psi''(a_i h_i) > 0$, 可知 $\psi(a_i h_i)$ 是凸函数, 存在全局最小极值。由文献^[18] 附录 A 可知, 只有当 $\|h_i\|_2$ 大于 $\psi(a_i h_i)$ 的极小值时, $a_i h_i$ 才有解, 否

则令 a_i 为 0,如图 4 所示。




图 4 $\psi(a_i, h_i)$ 的曲线图

Fig. 4 Plot of $\psi(a_i, h_i)$

因此,式(15)的解析式可表示为:

$$a_i = \begin{cases} 0 & \text{if } \|h_i\|_2 \leq \tilde{h} \\ \beta_i & \text{if } \|h_i\|_2 > \tilde{h} \end{cases}, \quad (18)$$

其中:软阈值 \tilde{h} 为 $\psi(a_i, h_i)$ 的极小值, β 为对应的缩放因子,可分别表示为:

$$\tilde{h} = \left(1 + \frac{2(1-\theta_i)}{\mu}\right) a_M + \frac{\theta_i p}{\mu} \|a_M\|_2^{p-1}, \quad (19)$$

$$a_M = \left(\frac{2\theta_i(1-p)}{\mu + 2(1-\theta_i)}\right)^{\frac{1}{2-p}}, \quad (20)$$

$$\beta_i^{t+1} = \frac{\mu}{\mu + 2(1-\theta_i)} \left(1 - \frac{\theta_i p}{\mu} \|h_i\|_2^{p-2} \|\beta_i^t\|_2^{p-1}\right), \quad (21)$$

其中, $\beta_i^0 \in [a_M \|h_i\|_2^{p-1}, 1]$ 是公式(21)的迭代初值,且由 S-ICP^[6]附录 C 可知,其将在两或三次迭代后收敛。

在此基础上,本文所提出的 SM-ICP 算法可通过 ADMM 双循环优化框架,避免离群值的影响并实现点云配准。其中,外循环利用公式(3)求解最近邻匹配点,并计算对应的欧式距离,进而通过公式(10)和(11)动态调整混合正则项的平衡权重。内循环则结合公式(4)、(5)和(6)求解对应的空间变换矩阵。最后,受离群值影响,迭代过程中停止准则可鲁棒的表示为源点云 X^k 和 X^{k-1} 的均方根误差。其中, $k \geq 1$ 表示迭代次数,即当对偶解收敛时,可得正确的匹配点对及其空间变换矩阵。本文算法的流程,如图 5 所示。

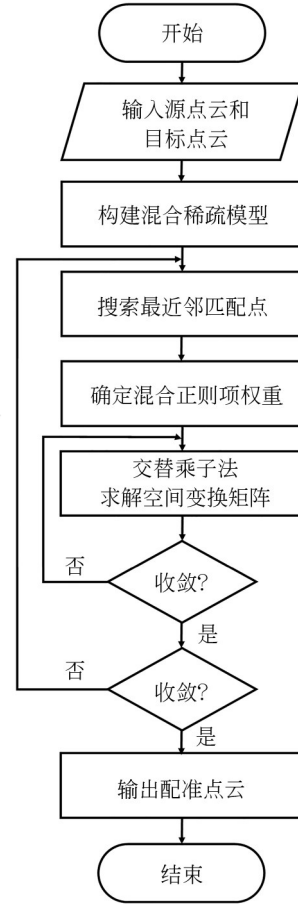


图 5 混合稀疏 ICP 算法流程图

Fig. 5 Flow chart of sparse mixture ICP algorithm

针对收敛性问题,由 3.1 节中的平衡权重确定方式可知,SM-ICP 算法将随着迭代次数的增加而趋同于 S-ICP 算法。由于 S-ICP 是收敛的,所以也间接证明了本文方法的收敛性。

4 实验与结果分析

在多视角点云配准任务中,离群值、噪声是现有配准方法面临的主要问题之一。因此,为了验证本文所提出 SM-ICP 算法的鲁棒性,设计了不同重叠率的斯坦福兔子点云配准实验。同时,设计了其它类型及存在噪声的部分重叠点云配准实验。为了验证 SM-ICP 算法的泛化性,还设计了重叠率较高的发动机叶片点云配准实验。在必要的预设参数中,包括 ICP^[5]在内的四种对比算法中 S-ICP^[6]和 Robust Tr-ICP^[8]的范数和能量函数内参分别选择其论文中所推荐的 $p=0.4$

和 $\text{inlier}=2$; SM-ICP 算法中的范数, 则设置为 $p=0.1$; 权重计算中涉及的缩放因子设置为 $v=0.9$; 全部对比算法的停止阈值都设置为 0.0001 ; 评价误差为截断均方根误差, 即对配准结果最近邻匹配点对的欧式距离从小到大排序后, 只截取和重叠率相同比率的点云均方根配准误差:

$$RMSE(X, Y) = \sqrt{\frac{\sum_{d=1}^{\xi n} R x_d + t - y_j}{\xi n}}, \quad (22)$$

其中: ξ 表示重叠率, $x_d \in X$ 表示匹配点对欧式距离 $d_i = \|x_i - y_i\|_2$, 从小到大排序后, 以 ξ 为比例所截取的欧式距离较小对应的点集。最后, 本章点云均缩放到边长为 1 m 的正方体中, 实验均在配置为 3.40 GHz Intel i7 CPU, 12 GB RAM 的个人计算机上的 MATLAB R2017b 完成。

4.1 斯坦福兔子点云配准实验

首先, 利用实际扫描的斯坦福数据集设计了四组不同重叠率的配准实验, 分别为第一组

(Bun180 和 Bun90, 约 50% 重叠)、第二组 (Bun315 和 Bun270, 约 60% 重叠)、第三组 (Bun180 和 Top2, 约 75% 重叠) 和第四组 (Bun000 和 Bun045, 约 90% 重叠)。首先, 对四种点云数据的源点云进行下采样, 得到数量为 $1800 \sim 2300$ 的采样点。在此基础上, 利用四种对比算法求解下采样点向目标点云进行配准的空间变换矩阵, 以实现源点云 (蓝色) 和目标点云 (红色) 配准。其中, 点云初始位姿及对应的配准结果如图 6 所示, 可知本文所提出的 SM-ICP 算法在点云初始位姿较差的情况下, 能 100% 成功地实现了四组不同重叠率的点云精确配准, 而其它对比方法或多或少的出现了配准失败的情况。

特别的, 在重叠率较低 (Bun180 和 Bun90, 约为 50%) 的配准任务中, 除了本文方法以外, 其它对比算法的配准结果出现了较为明显的点云错位现象, 其中本文方法的配准误差为 $2.04 \times 10^{-4} \text{ m}$, 较 Robust Tr-ICP 算法和 ICP 算法减小了一个量级, 较 S-ICP 算法减小了三倍。在点云配

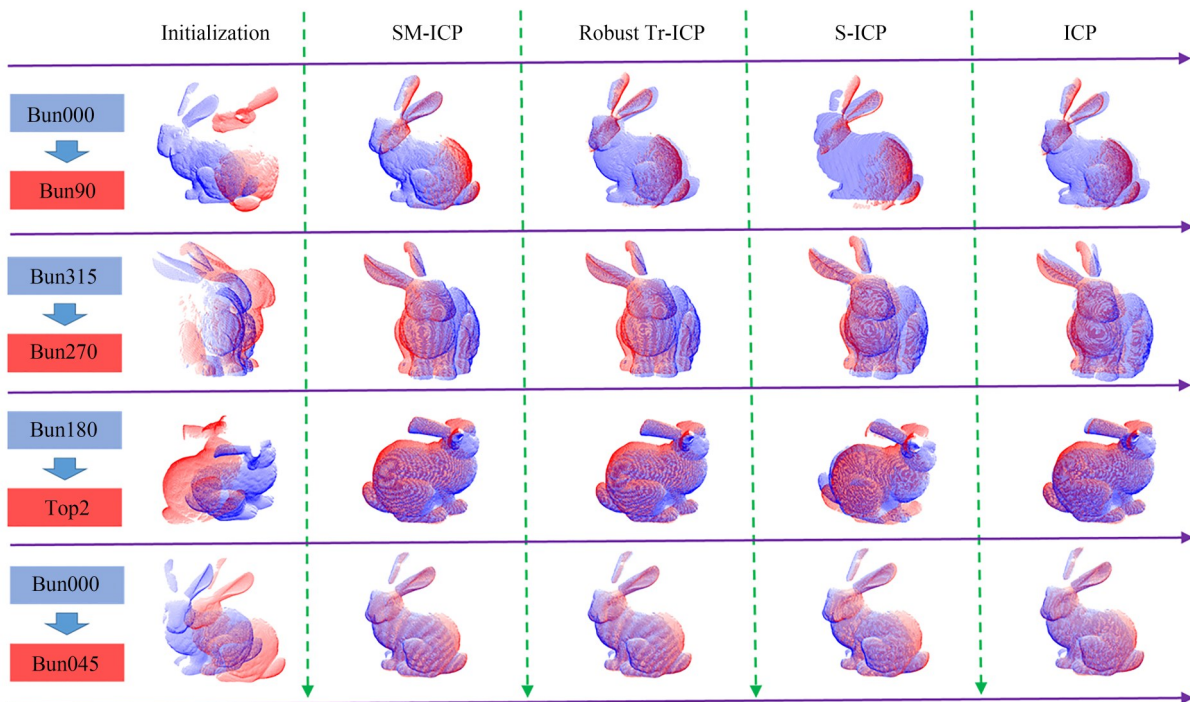


图 6 不同重叠率斯坦福兔子点云的初始位姿, 及其分别在 SM-ICP、Robust Tr-ICP、S-ICP 和 ICP 配准方法作用下的配准结果

Fig. 6 Initialization of Stanford bunny point-sets with different overlap rates, and the registration results of SM-ICP, Robust Tr-ICP, S-ICP and ICP on these dataset respectively

准效率方面,本文方法虽然较其它对比算法的配准精度较高,但是由于涉及了更复杂的双循环优化结构,可能较为耗时。然而,SM-ICP算法的平

均配准时间仅为 2.97 s,具体截断配准误差、配准时间如表 1 和图 7 所示。

表 1 四种对比算法应用于斯坦福兔子配准案例的截断误差和配准时间

Tab. 1 Both of the errors and time for the four comparison algorithms in the case of Stanford bunny point-sets.

Methods		Overlap rate			
		50%	60%	75%	90%
SM-ICP	Time/s	4.7	2.8	2.3	2.1
	Error/m	2.04×10^{-4}	7.75×10^{-6}	1.42×10^{-5}	1.14×10^{-5}
Robust Tr-ICP	Time/s	0.30	0.29	0.12	0.15
	Error/m	1.70×10^{-3}	7.95×10^{-6}	1.47×10^{-5}	1.18×10^{-5}
S-ICP	Time/s	1.38	0.6	0.2	0.68
	Error/m	8.96×10^{-4}	4.49×10^{-4}	7.34×10^{-4}	1.39×10^{-4}
ICP	Time/s	0.25	0.19	0.1	0.13
	Error/m	1.8×10^{-3}	9.07×10^{-5}	1.5×10^{-3}	2.53×10^{-4}




图 7 四种对比算法分别应用于斯坦福兔子配准案例的折线图

Fig. 7 Plot of the compared registration methods on Stanford bunny point-sets registration

为了进一步测试各算法的点云配准时间,本文以 Bun000 和 Bun045 的配准任务为例,对源点云 Bun000 进行了不同层级的下采样,并通过各对比算法令该下采样点向目标点云 Bun045 配准,得到对应的配准时间和精度。由图 8 可知,随着下采样点数的增加,本文提出的 SM-ICP 算法的点云配准时间逐渐增加且高于其它对比算法。然而,SM-ICP 算法在源点云的下采样点为 12 000 的配准任务中,其配准时间仅为 8.53 s。而且,当源点云的下采样点较少时,SM-ICP 算法不仅配准时间更少,其同样能实现良好的点云配

准精度,具体的截断配准误差和时间如表 2 所示。最后,为了更准确的描述配准结果,本文分别计算了各对比算法在 Bun180 和 Bun90 配准实验中所获得最近邻匹配点的欧式距离,并构建了距离直方图,如图 9 所示。本文方法约有一半的最近邻匹配点对距离小于 0.01 m,较稳健 Tr-ICP 多了约 45%,较 S-ICP 多了约 30%,较 ICP 多了约 40%,明显优于其它对比算法。本文算法在效率上虽然稍差于对比方法,但其始终保持了良好的精度和鲁棒性。




图 8 在不同层次下采样点的情况下,四种对比算法配准斯坦福数据(Bun000和Bun045)的折线图

Fig. 8 Plot of four compared algorithms on the Stanford data (Bun000 and Bun045) with different level of down-sampled points

表 2 在不同层次下采样点的情况下,四种对比算法配准斯坦福数据(Bun000和Bun045)的截断误差和配准时间

Tab. 2 Both trimmed error and registration time of four compared algorithms on the Stanford data (Bun000 and Bun045) with different level of down-sampled points

Method		The number of down-sampled points					
		2 000	4 000	6 000	8 000	1 0000	12 000
SM-ICP	Time/s	2.10	3.95	5.16	6.50	8.15	8.53
	Error/m	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}
Robust Tr-ICP	Time/s	0.17	0.31	0.43	0.57	0.73	0.85
	Error/m	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}	1.14×10^{-5}
S-ICP	Time/s	0.48	0.41	2.15	2.18	2.35	3.37
	Error/m	1.39×10^{-4}	1.40×10^{-4}	7.60×10^{-3}	7.00×10^{-3}	1.90×10^{-3}	1.70×10^{-3}
ICP	Time/s	0.31	0.27	0.34	0.50	0.54	0.68
	Error/m	2.80×10^{-4}	2.23×10^{-4}	2.09×10^{-4}	1.93×10^{-4}	1.77×10^{-4}	1.72×10^{-4}

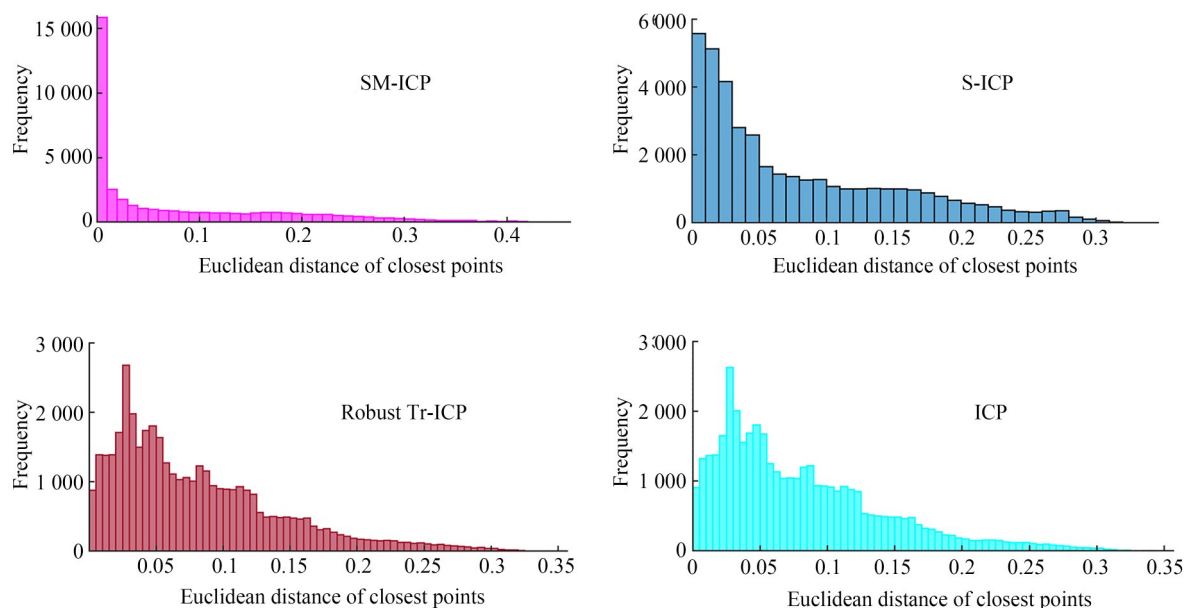


图 9 四种对比算法作用下,Bun180和Bun90配准结果的距离直方图

Fig. 9 Distance histograms of four comparison algorithms on the registration results of Bun180 and Bun90 point-sets

4.2 其它类型及存在噪声的点云配准实验

为了验证本文所提出 SM-ICP 的鲁棒性,本文还设计了其它类型及存在噪声的点云配准实验。其中,对于其他类型的点云配准实验,Buddha(重叠率约 90%)和 Dragon(重叠率约 50%)来源于斯坦福数据集,而 Coati(重叠率约 90%)和 Stage(重叠率约 60%)分别来自算法 4PCS^[19]和 Super4PCS^[20]。在此基础上,本文分别对其源

点云(蓝色)进行下采样,得到数量为 1 300~1 900 的数据点,并利用 SM-ICP 算法求解该数据点向目标点云(红色)配准的空间变换矩阵,实现部分重叠点云配准。其中,SM-ICP 的配准结果及点云的初始位姿,如图 10 所示。可以看出,SM-ICP 算法不仅适用于其它类型实体的多视角点云配准任务,而且对场景点云(Stage)配准任务同样具有良好的表现。

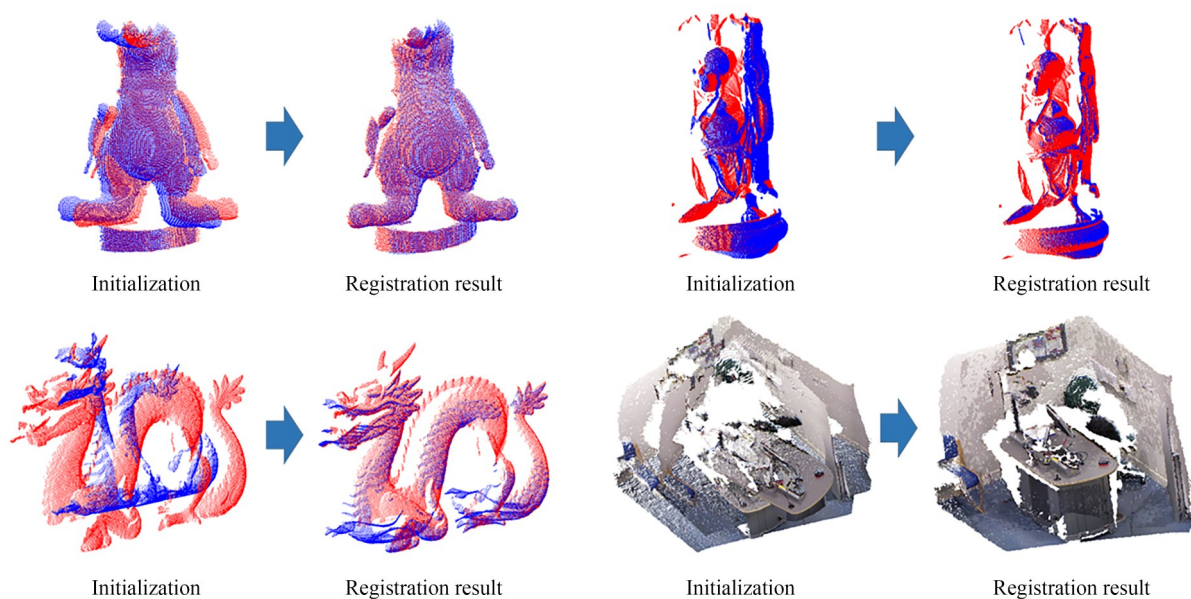


图 10 SM-ICP 算法应用于 Coati, Buddha, Dragon 和 Stage 数据集的配准结果

Fig. 10 Registration results of SM-ICP on the dataset, including Coati, Buddha, Dragon and Stage

具体的,与其它算法进行比较,本文分别计算了同等条件下各对比算法应用于图 10 配准任务的截断误差和配准时间,如表 3 所示。其中,

SM-ICP 应用于点云配准任务的全部截断误差均小于 1.93×10^{-5} m, 优于或等价于 Robust Tr-ICP, S-ICP 和 ICP 三种对比算法。虽然 SM-ICP

表 3 四种对比算法中应用于 Coati, Buddha, Dragon 和 Stage 数据集的配准误差和配准时间

Tab. 3 Both trimmed error and registration time of four compared algorithms on Coati, Buddha, Dragon and Stage point-sets registration

Methods		Dataset			
		Coati	Buddha	Dragon	Stage
SM-ICP	Time/s	0.92	2.62	3.63	1.33
	Error/m	7.50×10^{-6}	1.93×10^{-5}	7.70×10^{-6}	9.45×10^{-6}
Robust Tr-ICP	Time/s	0.09	0.31	0.66	0.36
	Error/m	7.70×10^{-6}	1.93×10^{-6}	7.79×10^{-6}	1.14×10^{-5}
S-ICP	Time/s	0.05	0.32	0.75	0.57
	Error/m	1.25×10^{-5}	3.63×10^{-5}	8.00×10^{-4}	1.97×10^{-5}
ICP	Time/s	0.04	0.25	0.35	0.318
	Error/m	1.69×10^{-5}	2.09×10^{-4}	7.69×10^{-3}	1.14×10^{-4}

的配准时间需要几秒,稍长于其它对比算法,但是其配准精度,除了在 Buddha 配准任务中等价于 Robust Tr-ICP 算法外,均优于其它对比算法,较 S-ICP 算法和 ICP 算法提升了 1~3 个量级。而且,在场景 Stage 点云配准实验中,SM-ICP 的配准时间仅为 1.33 s,配准误差为 $9.451.93 \times 10^{-6}$ m,较 Robust Tr-ICP 及其它对比算法更优。

另一方面,为了进一步验证 SM-ICP 算法的鲁棒性,本文以 Coati 点云配准任务为例,利用 MATLAB 中的 lhsdesign 函数,分别对源点云和

目标点云添加具有均匀性、随机性的随机噪声点。在此基础上,本文分别对源点云进行下采样,得到数量为 1 500~12 000 的下采样点,测试了本文提出的 SM-ICP 算法在具有不同层级噪声 ($N=1\ 000\sim 5\ 000$) 点云配准任务中的性能,如图 11 所示。可以看出,当点云的外围空间存在噪声点时,最近邻点的搜索会受到影响,使得点云配准任务更具挑战性。然而,SM-ICP 算法依然能成功地完成全部点云配准任务,表明其具有良好的鲁棒性。




图 11 在不同层次噪声 ($N=1\ 000\sim 5\ 000$) 的情况下,SM-ICP 算法应用于 Coati 点云的配准结果

Fig. 11 Registration results of SM-ICP on the Coati point-sets with different level of noises ($N=1\ 000\sim 5\ 000$)

与其它算法进行比较,本文计算了同等条件下各对比算法的配准时间和截断误差,如表 4 和图 12 所示。可以看出,本文提出的 SM-ICP 算法在不同层级随机噪声配准实验中,其截断误差始终优于其它对比算法。其中,一直表现较优的

Robust Tr-ICP 算法在源点云和目标点云分别添加 1000 个随机噪声点的情况下,其截断误差和其它两个对比算法都较 SM-ICP 算法增加了两个量级。另一方面,由图 12 可以看出,当噪声点数增多时,SM-ICP 的截断误差逐渐增大,而其它对比

表 4 在不同层次噪声的情况下,四种对比算法配准 Coati 点云的截断误差和配准时间

Tab. 4 Both trimmed error and registration time of four compared algorithms on the Coati point-sets with different level of noise points

Methods		The number of noises(The number of down-sampling)				
		1 000(1 400)	2 000(2 700)	3 000(4 500)	4 000(9 400)	5 000(11 550)
SM-ICP	Time/s	1.4	7.05	10.45	5.95	14.87
	Error/m	4.90×10^{-6}	6.82×10^{-5}	3.03×10^{-5}	8.39×10^{-5}	1.33×10^{-4}
Robust Tr-ICP	Time/s	0.17	0.07	0.35	0.87	1.69
	Error/m	4.98×10^{-4}	5.52×10^{-4}	1.89×10^{-4}	2.67×10^{-4}	2.13×10^{-4}
S-ICP	Time/s	0.09	0.12	0.13	0.42	1.05
	Error/m	4.92×10^{-4}	5.66×10^{-4}	5.56×10^{-4}	2.77×10^{-4}	2.72×10^{-4}
ICP	Time/s	0.04	0.28	0.19	0.62	1.13
	Error/m	5.13×10^{-4}	4.17×10^{-4}	3.81×10^{-4}	2.56×10^{-4}	3.66×10^{-4}

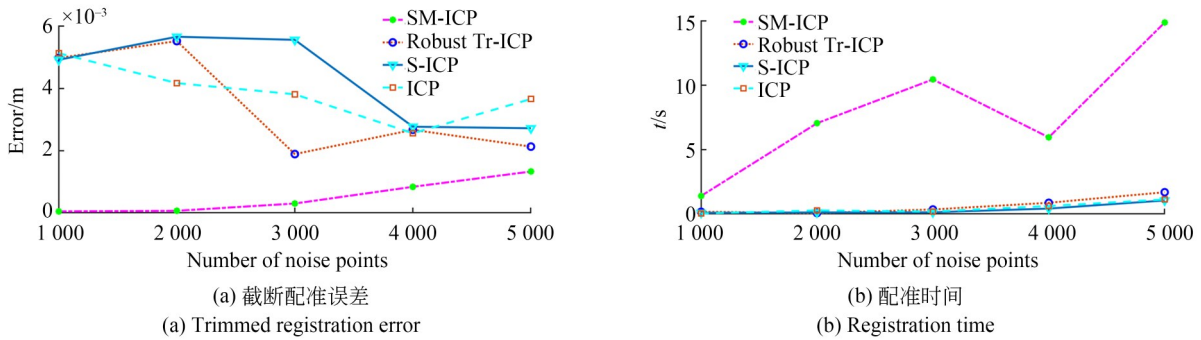


图 12 在不同层次噪声的情况下,四种对比算法配准 Coati 点云的折线图

Fig. 12 Plot of four compared algorithms on the Coati point-sets registration with different level of noise points

算法的截断配准误差逐渐减少,其可能是因为 Coati 配准任务的重叠率始终被设置为 90%,导致随着噪声点的增加离群渗入了截断误差的计算中,且噪声点密度的增加使其对应的最近邻点距离逐渐减少。因此,本文所提出 SM-ICP 算法不仅在具有随机噪声点的配准实验中具有良好的鲁棒性,且其配准精度较其它对比算法更优。最后,虽然 SM-ICP 算法的配准效率稍差于其它对比算法,但是其在下采样点为 11 550 的情况下的配准时间也只需要 14.87 s,同样适用于完成在线点云配准任务。

4.3 发动机叶片点云配准实验

在 4.1 节和在 4.2 节中的点云配准实验中,本文提出的 SM-ICP 算法虽然总体上较对比的算法具有更小的配准误差,但是在重叠率较高的配准实验中,Robust Tr-ICP 同样也实现了良好的配准结果且具有更好的配准效率。为了进一步验证 SM-ICP 算法的泛化性,本文设计了重叠率约为 90% 的发动机叶片点云配准实验,其初始位姿如图 13 所示。该点云数据^[21]由 CIMCORE 公司的高精度测量系统 INFINITE 测量得到。明显可以看出,发动机叶片点云的几何特征极为相似且不明显,使得该点云配准容易出现过拟合的结果。针对该配准任务,本文结合四种配准算法分别测试了发动机叶片源点云(酒红色)向目标点云(青色)的配准实验。

由图 14 可知,本文提出的 SM-ICP 算法依然




图 13 发动机叶片点云的初始位姿

Fig. 13 Initialization of engine blade point-sets

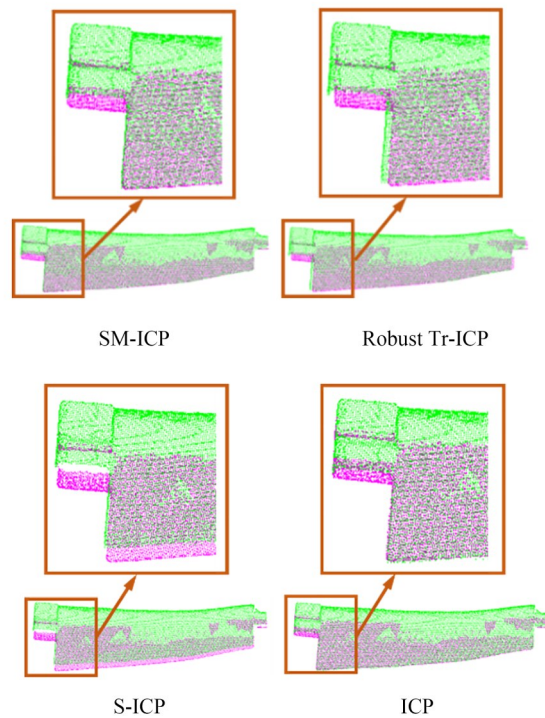


图 14 四种对比算法的发动机叶片点云配准结果

Fig. 14 Registration results of engine blade point-sets for four comparison algorithms.

保持了良好的配准精度,而 Robust Tr-ICP 算法和 S-ICP 算法都出现了不同程度的错位。此外,本文还截取了 SM-ICP 算法与 ICP 算法配准结果中的局部仰视图,可以看出 SM-ICP 算法所得配准结果同样较 ICP 算法更精确,如图 15 所示。因此,本文所提出的 SM-ICP 算法在几何特征不明显的发动机点云案例,较其它对比算法更具泛化性。




图 15 SM-ICP 与 ICP 算法配准结果的俯视图

Fig. 15 Vertical view of registration results for SM-ICP and ICP

参考文献:

- [1] 王宾,刘林,侯榆青,等. 应用改进迭代最近点方法的三维心脏点云配准[J]. 光学精密工程, 2020, 28(2): 474-484.
WANG B, LIU L, HOU Y Q, *et al.* Three-dimensional cardiac point cloud registration by improved iterative closest point method [J]. *Opt. Precision Eng.*, 2020, 28(2): 474-484. (in Chinese)
- [2] ZHEN X, SENG J C Y, SOMANI N. Adaptive Automatic Robot Tool Path Generation Based on Point Cloud Projection Algorithm [C]. 2019 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA), 2019.
- [3] 王锐,王世峰,常锴,等. 单线激光雷达与 GNSS/INS 的空间重构技术的研究[J]. 光学精密工程, 2020, 28(4): 851-858.
WANG R, WANG S F, CHANG K, *et al.* Space reconstruction using single-line LIDAR and GNSS/INS fused data[J]. *Opt. Precision Eng.*, 2020, 28(2): 851-858. (in Chinese)
- [4] 杨稳,周明全,耿国华,等. 层次优化的颅骨点云配准[J]. 光学精密工程, 2019, 27(12): 237-246.
YANG W, ZHOU M Q, GENG G H, *et al.* Hier-

5 结 论

本文根据三维点云模型重构精度高、鲁棒性强的要求,提出了 SM-ICP 点云配准方法,并构建了更具泛化性的混合稀疏点云配准函数。然后,研究了该配准函数涉及的交替乘子法优化框架和正则化损失函数的求解方法。最后,通过双循环的点云配准架构,对离群值进行惩罚,并实现了点云精确配准。实验结果证明:本文算法在重叠率约为 50%~90% 的斯坦福兔子和发动机叶片点云的配准实验中 100% 成功的实现了点云精确配准,全部配准案例中的配准误差小于或等于 $2.041.93 \times 10^{-4}$ m,最低为 $7.751.93 \times 10^{-6}$ m。此外,在其它类型、具有不同层次噪声和发动机叶片的点云配准实验,SM-ICP 同样较 Robust Tr-ICP, S-ICP 和 ICP 具有更高的配准精度。最后,在几何特征不明显的发动机叶片点云配准案例中,本文方法成功实现了点云精确配准,而其它对比算法的配准结果稍差。总结之,SM-ICP 具有良好的鲁棒性和泛化性。

- archical optimization of skull point cloud registration [J]. *Opt. Precision Eng.*, 2019, 27(12): 237-246.
- [5] BESL P J, MCKAY N D. A method for registration of 3-D shapes [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 14(2): 239-256.
- [6] BOUAZIZ S, TAGLIASACCHI A, PAULY M. Sparse iterative closest point [C]. *Eleventh Eurographics/acmsiggraph Symposium on Geometry Processing*, 2013.
- [7] CHETVERIKOV D, SVIRKO D, STEPANOV D, *et al.* The trimmed iterative closest point algorithm [J], 2002, 16(3): 545-548.
- [8] CHETVERIKOV D, STEPANOV D, KRSEK P. Robust euclidean alignment of 3D point sets: the trimmed iterative closest point algorithm [J]. *Image & Vision Computing*, 2005, 23(3): 299-309.
- [9] 李宁,赵永强,潘泉. 时空自适应的分焦平面偏振视频 PCA 去噪 [J]. 红外与激光工程, 2019, 48(10): 270-276.
LI N, ZHAO Y Q, PAN Q. PCA-based spatial-temporal adaptive denoising of DoFp video for mi-

- crogrid polarimeters [J]. *Infrared and Laser Engineering*, 2019, 48(10): 270-276.
- [10] 陈华伟,袁小翠,吴禄慎,等. 基于曲率突变分析的点云特征线自动提取[J]. *光学精密工程*, 2019, 027(005): 1218-1228.
CHEN H W, YUAN X C, WU L C, *et al.* Automatic point cloud feature-line extraction algorithm based on curvature-mutation analysis [J]. *Opt. Precision Eng.*, 2019, 27(5): 1218-1228.
- [11] GOJCIC Z, ZHOU C, WEGNER J D, *et al.* The Perfect Match: 3D point cloud matching with smoothed densities[C]. *Computer Vision and Pattern Recognition*, 2019.
- [12] AOKI Y, GOFORTH H, SRIVATSAN R A, *et al.* PointNetLK: Robust & Efficient Point Cloud Registration using PointNet[C]. *Computer Vision and Pattern Recognition*, 2019.
- [13] HUANG X, MEI G, ZHANG J. Feature-metric Registration: A Fast Semi-supervised Approach for Robust Point Cloud Registration without Correspondences [C]. *Computer Vision and Pattern Recognition*, 2020.
- [14] LI P, LI H Y, HUANG Y B, *et al.* Quasi-sparse response surface constructing accurately and robustly for efficient simulation based optimization [J]. *Advances in Engineering Software*, 2017, 114: 325-336.
- [15] LI P, HU S, LI H Y, *et al.* An improved quasi-sparse response surface model using the weighting method for low-dimensional simulation [J]. *Applied Soft Computing*, 2019, 85: 105883.
- [16] BOYD S, PARIKH N, CHU E, *et al.* Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. *Foundations & Trends® in Machine Learning*, 2010, 3(1): 1-122.
- [17] LANGE K. *The MM Algorithm*[M]. 2013.
- [18] MARJANOVIC G, SOLO V. On Lq Optimization and Matrix Completion [J]. *IEEE Transactions on Signal Processing*, 2012, 60(11): 5714-5724
- [19] AIGER D, MITRA N. J, COHEN-OR D. 4-points congruent sets for robust surface registration [J]. *ACM TOG (SIG-GRAPH)*, 2008, 85(3): 1-10.
- [20] NICOLAS M, NILOY, DROR A. SUPER 4PCS: Fast Global Point cloud Registration via Smart Indexing [J]. *Computer Graphics Forum*, 2014, 33(5): 205-215.
- [21] 张临池. 适应性移动最小二乘曲面的多视点云对齐方法[D]. 华中科技大学, 2012.
ZHANG L C. *Adaptive Moving Least-Squares Surfaces For Multiple Point Clouds Registration* [D]. Huazhong University of Science and Technology, 2012.

作者简介:



刘跃生(1992—),男,广东揭阳人,博士研究生,2015年于广东技术师范大学获得学士学位,2019年于广东工业大学获得硕士学位,现为广东工业大学机电工程学院博士研究生,主要从事计算机视觉及机器人控制方面的研究。E-mail: 2249791454@qq.com



陈新度(1967—),男,湖南长沙人,教授,博士生导师,分别在1989年、1992年和1995年于华中理工大学获得学士学位、硕士学位和博士学位,现为广东工业大学的教授,主要研究方向为网络化制造、制造系统建模和仿真优化。E-mail: 544394747@qq.com