

基于独立成分分析的三维点云配准算法

刘鸣¹, 舒勤^{1*}, 杨赞秀², 袁菲²

¹四川大学电气信息学院, 四川 成都 610065;

²西南技术物理研究所, 四川 成都 610041

摘要 点云配准是三维建模过程中的关键问题之一,快速高精度的配准是点云配准研究的重点。提出了一种利用独立成分分析(ICA)的点云配准方法,通过对两组点云数据作ICA,得到其独立分量、混合矩阵,以及解混合矩阵。由于ICA存在模糊问题,两点云的独立分量可能存在顺序和符号上的差异,在 F 范数最小的优化准则下可以得到两独立分量的最优变换矩阵。进一步,根据点云数据与独立分量之间的关系,实现点云的精确配准。实验结果表明,该算法配准速度快,具有较高的配准精度。

关键词 测量; 点云配准; 独立成分分析; F 范数

中图分类号 TP391 文献标识码 A

doi: 10.3788/LOP56.011203

Three-Dimensional Point Cloud Registration Based on Independent Component Analysis

Liu Ming¹, Shu Qin^{1*}, Yang Yunxiu², Yuan Fei²

¹School of Electrical Engineering and Information, Sichuan University, Chengdu, Sichuan 610065, China;

²Southwest Institute of Technical Physics, Chengdu, Sichuan 610041, China

Abstract Point cloud registration is one of the key issues in the process of three-dimensional modeling. Fast and high precision registration is the focus of point cloud registration. A method of point cloud registration based on independent component analysis (ICA) is proposed. The independent components, mixing matrix and unmixing matrix are obtained after ICA of two point cloud. Because of the fuzzy problem of ICA, the independent components of the two point cloud may have the difference in the order and the symbol. The optimal transformation matrix of two independent components can be obtained under the optimization criterion of minimum F norm. Further, the accurate registration of point clouds is achieved based on the relationship between point cloud data and independent components. Experimental results show that the proposed algorithm has faster registration speed and higher registration accuracy.

Key words measurement; point cloud registration; independent component analysis; F norm

OCIS codes 120.4640; 100.5010; 100.4999

1 引言

三维点云配准技术在逆向工程^[1-2]、计算机视觉和三维重构^[3-5]等领域有着广泛的应用,在三维点云激光扫描测量过程中可能需要从不同的角度对物体进行扫描^[6],因此需要对多组点云数据进行配准来得到完整的点云表达。经典的配准算法是Besl等^[7]提出的最近点迭代(ICP)算法以及其改进算

法^[8-11],该方法在两点云初始位置相近的情况下配准精度较高,但对配准初始条件要求较高,否则容易陷入局部最小值,且运算量大,对大规模点云数据配准时间很长。

快速精确的点云配准是三维建模和逆向工程领域的研究热点和难点,为了提高点云配准的精度和效率,Rusu等^[12]提出了点特征直方图和快速点特征直方图的特征提取方法,对噪声有一定的抑制作

收稿日期: 2018-06-26; 修回日期: 2018-07-06; 录用日期: 2018-07-18

基金项目: 四川省重点研发项目(2018GZ0226)

* E-mail: shuchin@163.com

用,但对于稠密点云计算点的特征会严重影响配准效率;Myronenko 等^[13]提出一致性点漂移(CPD)算法,该方法基于高斯混合模型进行点集匹配,对噪声及缺失点的影响具有较强稳健性,但对迭代初始值选取十分敏感,容易陷入局部最优,并且在大规模点云匹配时收敛速度较慢;雷玉珍等^[14]提出基于随机抽样一致算法的误匹配标志点校正方法;Wilkowski 等^[15]提出利用局部特征提取的配准方法;陈旭等^[16]提出一种基于校正点云主成分坐标系的快速全局配准算法;张哲等^[17]提出了一种基于关键点选择的快速点云配准;Ying 等^[18]提出基于 ICP 的尺度伸缩配准方法;舒程珣等^[19]提出基于卷积神经网络的点云配准方法。此外,陈凯等^[20]提出了基于 KD 树和点云特征的配准方法,该方法需要点云当中存在凸起、尖角等特殊区域才能很好实现配准。

基于以上情况,为了提高点云配准速度和精度,本文提出一种基于独立成分分析(ICA)的快速点云配准算法,通过点云数据的 ICA 分解得到独立分量,对独立分量进行变换实现点云配准。仿真实验结果表明:与其他算法相比较,本文算法配准速度较快,具有很高的配准精度。

2 点云配准

点云配准问题类似于数学上的映射问题,即找到两相邻点云数据集间的一种对应关系。定义激光点云集合为

$$\Omega = \{P_1, P_2, \dots, P_n\}, \quad (1)$$

式中 $P_k = \begin{Bmatrix} x_k \\ y_k \\ z_k \end{Bmatrix}, k=1, 2, \dots, n, n$ 为点云集合中的点

数。由该集合组成点云矩阵 $G_P = (P_1, P_2, \dots, P_n)$, 另外有待配准点云矩阵为 $G_Q = (Q_1, Q_2, \dots, Q_n)$ 。

点云配准就是让所有来自不同观测站的点云数据中代表物体表面同一点的点对 (P_k, Q_k) , 满足 $Q_k = R * P_k + T$, 其中 R 为旋转矩阵, T 为平移矩阵。通过此线性变换可将一个坐标系下的点云数据转换至另一坐标系下。配准结束后,两点云之间的配准误差表示为

$$\varepsilon = \frac{1}{n} \sum_{k=1}^n \|P_k * R + T - Q_k\|^2. \quad (2)$$

3 基于 ICA 的点云配准

3.1 ICA 的基本思想

ICA 寻求一个多元数据的非奇异变换,使得变

换后的数据分量之间尽可能地相互独立^[21-22]。ICA 假设有 n 个相互独立的随机变量 $s_1(t), s_2(t), \dots, s_n(t)$, m 个观测变量 $x_1(t), x_2(t), \dots, x_m(t)$, 观测向量 $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$ 与随机向量 $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$ 满足

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t), \quad (3)$$

式中 $\mathbf{A} \in \mathbb{R}^{m \times n} (n \leq m)$ 为未知混合矩阵。

ICA 模型的估计是指仅利用观测向量 $\mathbf{x}(t)$ 的样本数据,同时估计出未知混合矩阵 \mathbf{A} 和随机向量 $\mathbf{s}(t)$ 。ICA 估计方法通过寻求混合矩阵 $\mathbf{W} \in \mathbb{R}^{n \times m}$, 进而得到

$$\hat{\mathbf{s}}(t) = \mathbf{W}\mathbf{x}(t), \quad (4)$$

使得 $\hat{\mathbf{s}}(t)$ 中的各分量 $\hat{s}_1(t), \hat{s}_2(t), \dots, \hat{s}_n(t)$ 尽可能相互统计独立,从而得到独立成分的估计。FastICA 算法是简单有效的 ICA 估计方法,利用 FastICA 算法来估计混合矩阵和独立成分首先需要对观测变量 $x_1(t), x_2(t), \dots, x_m(t)$ 进行白化^[23],即

$$\mathbf{z}(t) = \mathbf{H}\mathbf{x}(t), \quad (5)$$

式中: $\mathbf{H} = \mathbf{\Gamma}^{-1/2} \mathbf{E}^T \in \mathbb{R}^{n \times m}$ 为白化矩阵; \mathbf{E} 为以协方差矩阵 $\mathbf{E}\{\mathbf{x}(t)\mathbf{x}(t)^T\}$ 的单位正交特征向量为列的矩阵; $\mathbf{\Gamma} = \text{diag}(\gamma_1, \gamma_2, \dots, \gamma_m)$ 为以 $\mathbf{E}\{\mathbf{x}(t)\mathbf{x}(t)^T\}$ 的特征值 $\gamma_1 \geq \gamma_2 \geq \dots \geq \gamma_m \geq 0$ 为对角元素的对角矩阵; $\mathbf{\Gamma}^{-1/2}$ 为对 $\mathbf{\Gamma}$ 的对角元素求代数平方根再取倒数后得到的对角矩阵的前 n 行组成的矩阵; n 为根据 $\gamma_1, \gamma_2, \dots, \gamma_m$ 的大小估计出的独立成分个数。白化处理使可观测信号的方差归一化,分离算法通常具有更好的稳定性并且收敛速度更快^[24]。

使用 FastICA 算法所估计出的独立成分的次序和符号无法确定,由于 $\mathbf{s}(t)$ 和 \mathbf{A} 都是未知的,因此可以交换模型中各独立分量的次序,也就是说可以利用一个矩阵 \mathbf{P} 及其逆代入模型,得到

$$\mathbf{x}(t) = \mathbf{A}\mathbf{P}^{-1}\mathbf{P}\mathbf{s}(t). \quad (6)$$

向量 $\mathbf{P}\mathbf{s}(t)$ 的分量仍然是由原来的随机变量 $\hat{s}_1(t), \hat{s}_2(t), \dots, \hat{s}_n(t)$ 组成,只是顺序和符号发生了变化,此时 $\mathbf{A}\mathbf{P}^{-1}$ 为新的未知混合矩阵。

3.2 点云数据的 ICA 分析

通过不同视角扫描得到的点云集合分别为

$$\mathbf{A} = \begin{pmatrix} \mathbf{X}_A \\ \mathbf{Y}_A \\ \mathbf{Z}_A \end{pmatrix}, \mathbf{B} = \begin{pmatrix} \mathbf{X}_B \\ \mathbf{Y}_B \\ \mathbf{Z}_B \end{pmatrix}, \quad (7)$$

式中 \mathbf{A} 为原始点云集合, \mathbf{B} 为待配准的点云集合, 并且 $\mathbf{A} = T(\mathbf{B})$, T 为线性变换函数,即点云集合 \mathbf{A} 可以由点云集合 \mathbf{B} 通过线性变换得到。

将两组点云去除均值可以得到:

$$\begin{cases} \tilde{\mathbf{A}} = \mathbf{A} - \text{mean}\{\mathbf{A}\} = \begin{pmatrix} \mathbf{X}_A - \text{mean}\{\mathbf{X}_A\} \\ \mathbf{Y}_A - \text{mean}\{\mathbf{Y}_A\} \\ \mathbf{Z}_A - \text{mean}\{\mathbf{Z}_A\} \end{pmatrix} \\ \tilde{\mathbf{B}} = \mathbf{B} - \text{mean}\{\mathbf{B}\} = \begin{pmatrix} \mathbf{X}_B - \text{mean}\{\mathbf{X}_B\} \\ \mathbf{Y}_B - \text{mean}\{\mathbf{Y}_B\} \\ \mathbf{Z}_B - \text{mean}\{\mathbf{Z}_B\} \end{pmatrix} \end{cases} \quad (8)$$

三维点云数据在存储时保存了每个扫描点在空间中的坐标,这里 \mathbf{A} 和 \mathbf{B} 都是 $3 \times n$ 的矩阵,在对其进行 ICA 分解时,选择信源信号的个数为 3。假设存在 3 个相互正交的行向量 s_x, s_y, s_z ,那么存在混合矩阵 $\mathbf{M}_1, \mathbf{M}_2$ 使得:

$$\tilde{\mathbf{A}} = \mathbf{M}_1 \begin{pmatrix} s_x \\ s_y \\ s_z \end{pmatrix}, \tilde{\mathbf{B}} = \mathbf{M}_2 \begin{pmatrix} s_x \\ s_y \\ s_z \end{pmatrix} \quad (9)$$

两组点云数据通过 ICA 分离后可以分别得到独立成分 $\mathbf{S}_A = \begin{pmatrix} s_{A1} \\ s_{A2} \\ s_{A3} \end{pmatrix}, \mathbf{S}_B = \begin{pmatrix} s_{B1} \\ s_{B2} \\ s_{B3} \end{pmatrix}$ 及其混合矩阵 $\hat{\mathbf{M}}_1, \hat{\mathbf{M}}_2$ 。

由于 ICA 算法存在的模糊问题,独立成分的顺序和符号不能确定,因此存在一个 3×3 的矩阵 \mathbf{P} ,使得:

$$\mathbf{S}_A = \mathbf{P}\mathbf{S}_B + \mathbf{D}, \quad (10)$$

式中 \mathbf{S}_A 和 \mathbf{S}_B 两独立分量中各自的成分都是相互独立的, \mathbf{D} 为与 \mathbf{S}_A 维数相同的误差矩阵。对 \mathbf{D} 求 F 范数得到:

$$\begin{aligned} \|\mathbf{D}\|_F &= \sqrt{\text{tr}(\mathbf{D}\mathbf{D}^T)} = \\ &= \sqrt{\text{tr}[(\mathbf{S}_A - \mathbf{P}\mathbf{S}_B)(\mathbf{S}_A - \mathbf{P}\mathbf{S}_B)^T]} = \\ &= \sqrt{\text{tr}(\mathbf{S}_A\mathbf{S}_A^T - \mathbf{P}\mathbf{S}_B\mathbf{S}_A^T - \mathbf{S}_A\mathbf{S}_B^T\mathbf{P}^T + \mathbf{P}\mathbf{S}_B\mathbf{S}_B^T\mathbf{P}^T)}, \end{aligned} \quad (11)$$

令 $\mathbf{l} = \mathbf{S}_A\mathbf{S}_A^T - \mathbf{P}\mathbf{S}_B\mathbf{S}_A^T - \mathbf{S}_A\mathbf{S}_B^T\mathbf{P}^T + \mathbf{P}\mathbf{S}_B\mathbf{S}_B^T\mathbf{P}^T, \mathbf{S}_B\mathbf{S}_B^T$ 为对称矩阵,对其作奇异值分解:

$$\mathbf{S}_B\mathbf{S}_B^T = \mathbf{V}\mathbf{\Sigma}\mathbf{V}^T, \quad (12)$$

式中 $\mathbf{\Sigma}$ 为 3×3 的对角矩阵, \mathbf{V} 为 3×3 的正交矩阵。则有:

$$\begin{aligned} \mathbf{l} &= \mathbf{P}\mathbf{V}\mathbf{\Sigma}\mathbf{V}^T - \mathbf{P}\mathbf{S}_B\mathbf{S}_A^T - \mathbf{S}_A\mathbf{S}_B^T\mathbf{P}^T + \mathbf{S}_A\mathbf{S}_A^T = \\ &= \mathbf{P}\mathbf{V}\mathbf{\Sigma}^{1/2}\mathbf{\Sigma}^{1/2}\mathbf{V}^T - \mathbf{P}\mathbf{S}_B\mathbf{S}_A^T - \mathbf{S}_A\mathbf{S}_B^T\mathbf{P}^T + \mathbf{S}_A\mathbf{S}_A^T = \\ &= (\mathbf{P}\mathbf{V}\mathbf{\Sigma}^{1/2} - \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}\mathbf{\Sigma}^{-1/2}) \\ &= (\mathbf{P}\mathbf{V}\mathbf{\Sigma}^{1/2} - \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}^T\mathbf{\Sigma}^{-1/2})^T - \\ &= \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}^T\mathbf{\Sigma}^{-1/2}\mathbf{\Sigma}^{-1/2}\mathbf{V}\mathbf{S}_B\mathbf{S}_A^T + \mathbf{S}_A\mathbf{S}_A^T = \\ &= \|\mathbf{P}\mathbf{V}\mathbf{\Sigma}^{1/2} - \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}\mathbf{\Sigma}^{-1/2}\|^2 - \\ &= \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}^T\mathbf{\Sigma}^{-1/2}\mathbf{\Sigma}^{-1/2}\mathbf{V}\mathbf{S}_B\mathbf{S}_A^T + \mathbf{S}_A\mathbf{S}_A^T. \end{aligned} \quad (13)$$

当 $\mathbf{P}\mathbf{V}\mathbf{\Sigma}^{1/2} = \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}\mathbf{\Sigma}^{-1/2}$, 即:

$$\mathbf{P} = \mathbf{S}_A\mathbf{S}_B^T\mathbf{V}\mathbf{\Sigma}^{-1}\mathbf{V}^T = \mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}, \quad (14)$$

此时 \mathbf{l} 有最小值,则误差矩阵 \mathbf{D} 具有最小的 F 范数。

将矩阵 $\mathbf{P} = \mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}$ 代入(10)式,原始点云数据的独立分量可以表示为

$$\mathbf{S}_A = \mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}\mathbf{S}_B. \quad (15)$$

进一步得到原始点云数据:

$$\mathbf{A} = \hat{\mathbf{M}}_1\mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}\mathbf{S}_B\hat{\mathbf{M}}_2^{-1}\tilde{\mathbf{B}} + \text{mean}\{\mathbf{A}\}. \quad (16)$$

上述分析表明,点云数据 ICA 分解得到的独立成分是后续配准工作的基础,通过 ICA 分解获得两点云独立成分之后,根据(16)式可以得到不同视角点云数据的配准,其中旋转矩阵可以看作:

$$\mathbf{R} = \hat{\mathbf{M}}_1\mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}\mathbf{S}_B\hat{\mathbf{M}}_2^{-1}. \quad (17)$$

该旋转矩阵与去除均值之后的待配准点云数据相乘,再加上原始点云数据的均值得到平移矩阵:

$$\mathbf{T} = \text{mean}\{\mathbf{A}\}. \quad (18)$$

本文算法流程图如图 1 所示。

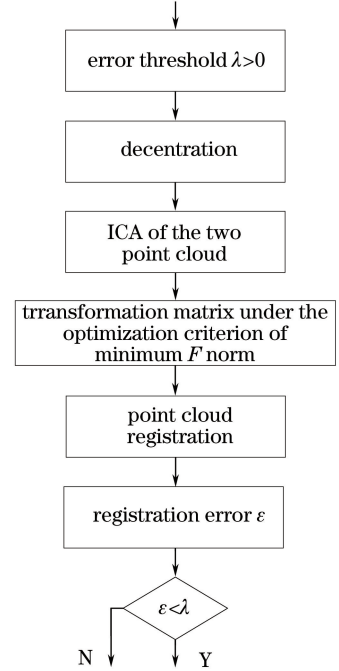


图 1 算法流程图

Fig. 1 Flow chart of proposed algorithm

相应的伪代码如下:

Input: $\mathbf{A} \leftarrow$ original point cloud, $\mathbf{B} \leftarrow$ pre-registration point cloud, error threshold λ
 $\mathbf{A} \leftarrow \mathbf{A} - \text{mean}(\mathbf{A}), \mathbf{B} \leftarrow \mathbf{B} - \text{mean}(\mathbf{B})$
 $\mathbf{S}_A \leftarrow \text{ICA}(\mathbf{A}), \mathbf{S}_B \leftarrow \text{ICA}(\mathbf{B})$
 $\mathbf{P} \leftarrow \mathbf{S}_A\mathbf{S}_B^T(\mathbf{S}_B\mathbf{S}_B^T)^{-1}$
 for $k \leftarrow 1$ to n

```

do error ← error + || $\mathbf{A}_k * \mathbf{R} + \mathbf{T} - \mathbf{B}_k$ ||2
 $\epsilon \leftarrow \frac{1}{n}$  error
if  $\epsilon < \lambda$ 
then registration succeed
else registration failed

```

4 配准实验与误差分析

为验证本文方法的有效性,在 Intel i5 CPU、4 GB 内存的计算机上采用 Matlab 编程进行仿真和实例分析。在实验中,待配准点云的初始位置均任意。经典数据选取斯坦福大学计算机图形研究组的 Bunny 多视角数据,另外有实例点云数据的配准分析。

4.1 经典数据配准

在 Bunny 点云配准中,分别对两点云数据进行

ICA 分解,得到其独立成分如图 2 所示,可以看到,由于 ICA 的模糊性,其独立成分的顺序和符号可能会有差异。

图 3 为 Bunny 数据配准结果,该组点云包含 31067 个点。图 3(a)为配准前的源点云和待配准点云有重叠的效果图,图 3(b)~(e)分别为本文配准算法、ICP 尺度伸缩算法、CPD 配准算法,以及传统 ICP 算法的配准结果。由图 3 可知,这些方法均能完成点云的配准,但直接用经典 ICP 算法和 CPD 算法,整体上点的精确重合程度稍弱,边缘部分误差比较明显,本文算法和 ICP 尺度伸缩算法配准效果较好,更精细的误差以及时间对比如表 1 所示。

在 Elephant 点云配准中,通过对两点云数据进行 ICA 分解,得到其独立成分如图 4 所示,各独立分量有明显的分布特征。

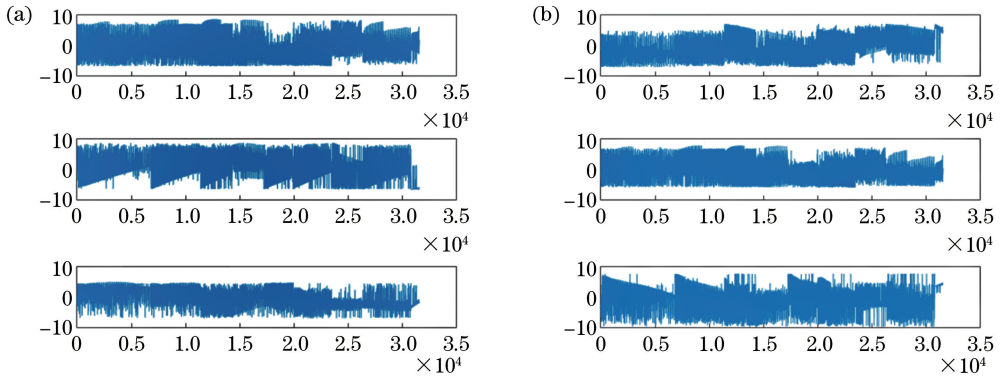


图 2 Bunny 点云。(a)源点云独立分量特征图;(b)待配准点云独立分量特征图

Fig. 2 Point cloud of Bunny. (a) Independent component feature graph of original point cloud; (b) independent component feature graph of unregistered point cloud

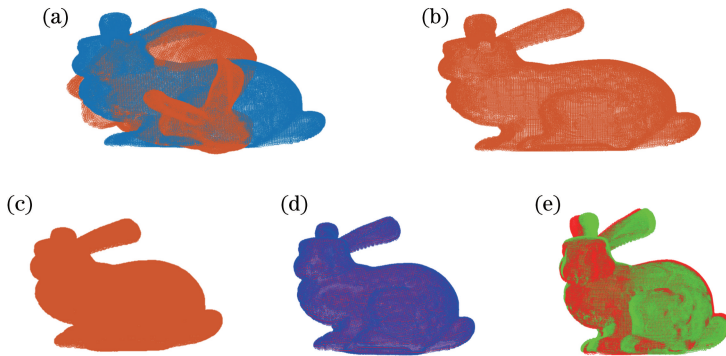


图 3 Bunny 配准。(a)配准前的点云;(b)本文算法配准;(c) ICP 尺度伸缩算法配准;(d) CPD 算法配准;(e)经典 ICP 算法配准

Fig. 3 Registration of Bunny. (a) Pre-registration point cloud; (b) registration by the proposed algorithm; (c) registration by scale-ICP algorithm; (d) registration by CPD algorithm; (e) registration by classic ICP algorithm

表 1 不同算法的点云配准对比

Table 1 Comparison of point cloud registrations with different algorithms

Point cloud	Algorithm	Time /s	MSE /mm
Bunny	ICP	53.476	0.195
	CPD algorithm	28.473	1.098×10^{-10}
	Scale-ICP algorithm	6.695	8.439×10^{-15}
	Proposed algorithm	0.831	1.625×10^{-28}
Elephant	ICP	38.405	0.014
	CPD algorithm	21.055	1.1577×10^{-8}
	Scale-ICP algorithm	5.724	7.559×10^{-16}
	Proposed algorithm	0.473	2.246×10^{-30}

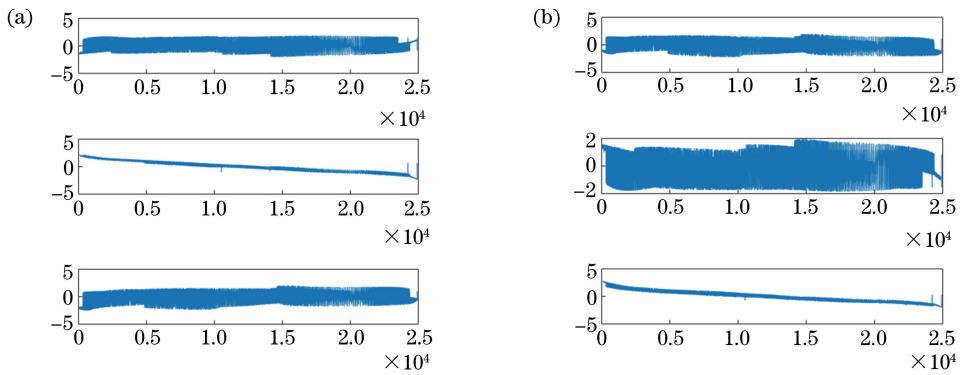


图 4 Elephant 点云。(a)源点云独立分量特征图;(b)待配准点云独立分量特征图

Fig. 4 Point cloud of Elephant. (a) Independent component feature graph of original point cloud;

(b) independent component feature graph of unregistered point cloud

图 5 为 Elephant 点云配准结果,该组点云包含 24955 个点。图 5(a)为配准前有重叠的点云,通过本文算法以及其他配准算法得到图 5(b)~(e)的配准结果,由图 5 可知,本文算法和 ICP 尺度伸缩算

法的配准精度高于 CPD 算法和 ICP 算法。经典 ICP 算法由于配准结果受初始值的影响比较明显等原因,点云边缘有没对齐的部分。表 1 为几种算法的配准结果对比。

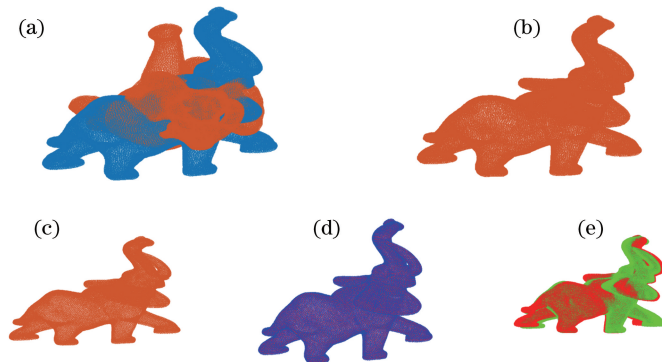


图 5 Elephant 配准图。(a)配准前的点云;(b)本文算法配准;(c) ICP 尺度伸缩算法配准;

(d) CPD 算法配准;(e)经典 ICP 算法配准

Fig. 5 Registration of Elephant. (a) Pre-registration point cloud; (b) registration by the proposed algorithm; (c) registration by scale-ICP algorithm; (d) registration by CPD algorithm; (e) registration by classic ICP algorithm

为了进一步比较本文算法与其他配准算法的配准性能,对 Bunny 点云和 Elephant 点云采用不同算法进行 20 次配准,得到的平均配准时间和平均配准误差(MSE)如表 1 所示。

由表 1 可知,在 Bunny 和 Elephant 点云配准中,本文算法、scale-ICP 算法和 CPD 算法均能实现高精度的配准,且本文算法的配准精度最高,经典 ICP 算法的配准效果略差。在配准速度上,本文算

法所需时间最少。在 Bunny 点云配准中,本文算法配准时间分别为经典 ICP 算法的 1.55%、CPD 算法的 2.92%、ICP 尺度伸缩算法的 12.4%;在 Elephant 点云配准中,本文算法的配准时间分别为经典 ICP 算法的 1.24%、CPD 算法的 2.25%、ICP 尺度伸缩算法的 8.26%。综合来看,本文算法在配准速度上更快,同时配准精度较高。

4.2 有噪声点云数据配准

考虑到在实际点云的扫描过程中会有噪声的影响,为了检验本文算法在噪声背景下的配准效果,进

行了有噪声的点云数据配准实验。实验数据选用 Bunny 点云,待配准数据 Bunny 点云中添加了信噪比为 20 dB 的噪声,图 6(a)为配准前的三维点云图。

由图 6 可知,在随机加入信噪比为 20 dB 的噪声后,本文算法仍能完成配准,在配准时间上与未加入噪声时差别不大,配准误差与 CPD 算法和改进 ICP 算法相当。经典 ICP 算法的配准误差在几种算法中最大,噪声加入后,CPD 算法、改进 ICP 算法以及经典 ICP 算法的配准时间都明显增加。

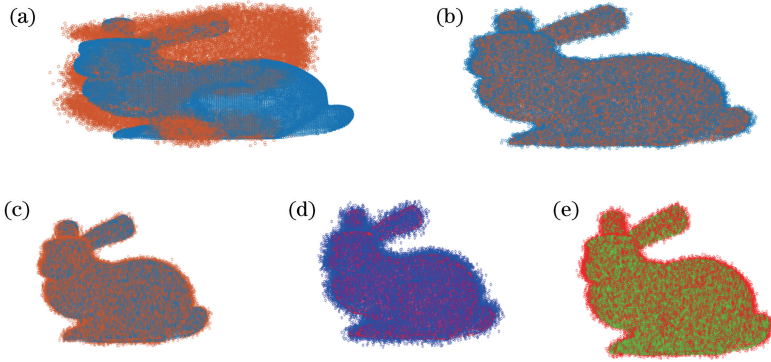


图 6 加入噪声后的点云配准。(a)配准前的点云;(b)本文算法配准;(c) ICP 尺度伸缩算法配准;(d) CPD 算法配准;(e)经典 ICP 算法配准

Fig. 6 Point cloud registration after adding noise. (a) Pre-registration point cloud; (b) registration by the proposed algorithm; (c) registration by scale-ICP algorithm; (d) registration by CPD algorithm; (e) registration by classic ICP algorithm

表 2 加入噪声后的点云配准比较

Table 2 Comparison of point cloud registrations after adding noise

Algorithm	Time /s	MSE /mm
ICP	67.352	0.2687
CPD algorithm	37.427	0.1021
Scale-ICP algorithm	11.946	0.1301
Proposed algorithm	0.974	0.1025

4.3 实际数据配准

在实际应用中配准算法应保证可行性与可靠

性,为此对现场扫描数据进行配准验证。图 7(a)为激光扫描仪从不同角度采集得到的零件配准前的点云图,该零件点云图包含 273871 个点。利用本文算法进行配准并与 CPD 算法、改进 ICP 算法和经典 ICP 算法的配准结果作对比,图 7(b)~(e)分别为利用上述算法的配准结果。对源点云和待配准点云分别做 ICA 分析,得到独立成分特征如图 8 所示,基于此完成配准过程平均用了 2.534 s,比其余三种算法都要快很多。同时本文算法点云配准效果良

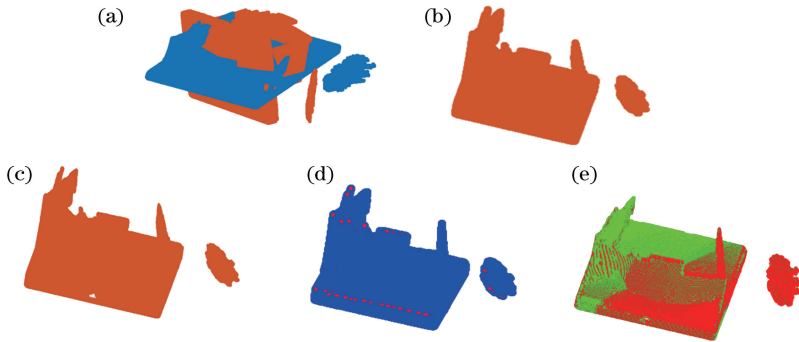


图 7 零件配准图。(a)配准前的点云;(b)本文算法配准;(c) ICP 尺度伸缩算法配准;(d) CPD 算法配准;(e)经典 ICP 算法配准

Fig. 7 Registration of spare part. (a) Pre-registration point cloud; (b) registration by the proposed algorithm; (c) registration by scale-ICP algorithm; (d) registration by CPD algorithm; (e) registration by classic ICP algorithm

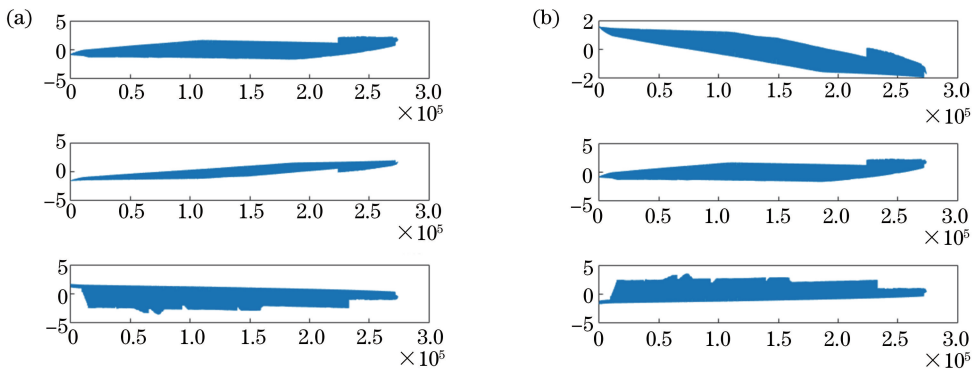


图8 零件点云图。(a)源点云独立分量特征图;(b)待配准点云独立分量特征图

Fig. 8 Point cloud of spare part. (a) Independent component feature graph of original point cloud;
(b) independent component feature graph of unregistered point cloud

好,平均配准误差在 10^{-22} 量级上,能够实现高精度配准。

将扫描实际零件得到的点云数据作为配准点云,用本文算法和CPD算法、改进ICP算法,以及经典ICP算法分别完成20次配准,得到的配准时间和误差对比如表3所示。

表3 零件点云配准比较

Table 3 Comparison of point cloud registrations of spare part

Algorithm	Time /s	MSE /mm
ICP	196.352	0.385
CPD algorithm	124.427	3.0605×10^{-14}
Scale-ICP algorithm	102.857	3.4667×10^{-11}
Proposed algorithm	2.534	9.019×10^{-22}

由表3可知,在对零件点云的配准中,直接采用ICP算法和CPD算法得到的结果误差较大,在零件的边缘和突出点处有未重合区域。利用本文算法和改进ICP算法可以得到更精确的配准,其中本文算法的配准精度最高,且相比于其余三种算法所需的配准时间最少。对经典点云数据和实际扫描得到点云数据的配准和相关配准算法的数据对比,表明本文算法具有良好的性能,能够更快地实现高精度的点云配准。

5 结 论

点云配准在逆向工程、计算机视觉和图形数据库基于图形的查找中有着广泛的应用,而点云快速配准对现有配准方法是个挑战。因此提出一种基于ICA的点云配准算法,将点云的三维坐标看作三个独立分量,通过ICA分解得到源点云和待配准点云的独立成分,将点云处理转化为对其独立成分的分析 and 变换。经典点云数据配准和实际扫描数据的实

验结果均表明:与其他算法相比较,本文算法具有更快的配准速度、更高的配准精度,以及一定的抑制噪声能力。本文算法将点云在不同坐标上的独立成分作为研究对象,如果物体在三个坐标轴方向上的分布一致或者差异不大,配准的精度会受到影响。本文算法实现了数据点数目相同的两点云快速配准,而点数不一致配准是下一步需要研究的问题。

参 考 文 献

- [1] Muslimin, Yoshioka H, Zhu J, *et al.* Automatic segmentation and feature identification of laser scanning point cloud data for reverse engineering[C]//Proceedings of 2016 International Symposium on Flexible Automation, 2016: 278-285.
- [2] Fan L P, Liu H S, Rao X X, *et al.* The point cloud data alignment method research in reverse engineering [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2012, 4: 9-11.
樊丽萍, 柳和生, 饶锡新, 等. 逆向工程中点云数据配准方法研究[J]. 组合机床与自动化加工技术, 2012, 4: 9-11.
- [3] Guo W, Cheng X J. Registration method for airborne and terrestrial light detection and ranging point cloud based on laser intensity classification [J]. Laser & Optoelectronics Progress, 2018, 55(6): 062803.
郭王, 程效军. 基于激光强度分类的机载与地面激光雷达点云配准方法[J]. 激光与光电子学进展, 2018, 55(6): 062803.
- [4] Thanh N T, Liu X G, Wang H P, *et al.* 3D model reconstruction based on laser scanning technique[J]. Laser & Optoelectronics Progress, 2011, 48(8): 081201.
Nguyen Tien Thanh, 刘修国, 王红平, 等. 基于激光扫描技术的三维模型重建[J]. 激光与光电子学进

- 展, 2011, 48(8): 081201.
- [5] Xiao Y, Hu S X, Xiao S, *et al.* A fast statistical method of tree information from 3D laser point clouds [J]. Chinese Journal of Lasers, 2018, 45(5): 0510007.
肖杨, 胡少兴, 肖深, 等. 从三维激光点云中快速统计树木信息的方法[J]. 中国激光, 2018, 45(5): 0510007.
- [6] Chen T. Data processing methodology for laser measurement point cloud [J]. Laser & Optoelectronics Progress, 2011, 48(9): 091202.
陈田. 激光测量点云的数据处理方法研究[J]. 激光与光电子学进展, 2011, 48(9): 091202.
- [7] Besl P J, McKay N D. A method for registration of 3-D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [8] Zhao M B, He J, Luo X B, *et al.* Two-viewing angle lidar data registration based on improved iterative closest-point algorithm [J]. Acta Optica Sinica, 2012, 32(11): 1128007.
赵明波, 何峻, 罗小波, 等. 基于改进迭代最近点算法的两视角激光雷达数据配准[J]. 光学学报, 2012, 32(11): 1128007.
- [9] Zeng F X, Li L, Diao X P. Iterative closest point algorithm registration based on curvature features [J]. Laser & Optoelectronics Progress, 2017, 54(1): 011003.
曾繁轩, 李亮, 刁鑫鹏. 基于曲率特征的迭代最近点算法配准研究[J]. 激光与光电子学进展, 2017, 54(1): 011003.
- [10] Yang J L, Li H D, Campbell D, *et al.* Go-ICP: a globally optimal solution to 3D ICP point-set registration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(11): 2241-2254.
- [11] Li R Z, Yang M, Tian Y, *et al.* Point cloud registration algorithm based on the ISS feature points combined with improved ICP algorithm [J]. Laser & Optoelectronics Progress, 2017, 54(11): 111503.
李仁忠, 杨曼, 田瑜, 等. 基于 ISS 特征点结合改进 ICP 的点云配准算法 [J]. 激光与光电子学进展, 2017, 54(11): 111503.
- [12] Rusu R B, Blodow N, Marton Z C, *et al.* Aligning point cloud views using persistent feature histograms [C] // Proceedings of 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2008: 3384-3391.
- [13] Myronenko A, Song X B. Point set registration: coherent point drift [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(12): 2262-2275.
- [14] Lei Y Z, Li Z W, Zhong K, *et al.* Mismatching marked points correction method based on random sample consensus algorithm [J]. Acta Optica Sinica, 2013, 33(3): 0315002.
雷玉珍, 李中伟, 钟凯, 等. 基于随机抽样一致算法的误匹配标志点校正方法 [J]. 光学学报, 2013, 33(3): 0315002.
- [15] Wilkowski A, Stefańczyk M. Detection and recognition of compound 3D models by hypothesis generation [C] // Proceedings of International Conference on Automation, 2016: 659-668.
- [16] Chen X, He B W. A fast global registration algorithm based on correcting point cloud principal component coordinate system [J]. Laser & Optoelectronics Progress, 2018, 55(6): 061003.
陈旭, 何炳蔚. 一种基于校正点云主成分坐标系的快速全局配准算法 [J]. 激光与光电子学进展, 2018, 55(6): 061003.
- [17] Zhang Z, Xu H L, Yin H. A fast point cloud registration algorithm based on key point selection [J]. Laser & Optoelectronics Progress, 2017, 54(12): 121002.
张哲, 许宏丽, 尹辉. 一种基于关键点选择的快速点云配准算法 [J]. 激光与光电子学进展, 2017, 54(12): 121002.
- [18] Ying S H, Peng J G, Du S Y, *et al.* A scale stretch method based on ICP for 3D data registration [J]. IEEE Transactions on Automation Science and Engineering, 2009, 6(3): 559-565.
- [19] Shu C X, He Y T, Sun Q K. Point cloud registration based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2017, 54(3): 031001.
舒程珣, 何云涛, 孙庆科. 基于卷积神经网络的点云配准方法 [J]. 激光与光电子学进展, 2017, 54(3): 031001.
- [20] Chen K, Zhang D, Zhang Y S. Point cloud data processing method of cavity 3D laser scanner [J]. Acta Optica Sinica, 2013, 33(8): 0812003.
陈凯, 张达, 张元生. 采空区三维激光扫描点云数据处理方法 [J]. 光学学报, 2013, 33(8): 0812003.
- [21] Yang J C, Zhang N. A review of independent component analysis [J]. Ship Science and Technology, 2007, 29(2): 83-86.
杨金成, 张南. 独立成分分析技术综述 [J]. 舰船科

- 学技术, 2007, 29(2): 83-86.
- [22] Jutten C. Independent components analysis versus principal components analysis [J]. Signal Processing IV Theories & Applications Grenoble France, 1988, 12(3): 41-64.
- [23] Boveressee D J R, Rutledge D N. Independent components analysis: theory and applications [J]. Data Handling in Science and Technology, 2016, 30: 225-277.
- [24] Jia R S, Zhao T B, Sun H M, *et al.* Micro-seismic signal denoising method based on empirical mode decomposition and independent component analysis [J]. Chinese Journal of Geophysics, 2015, 58(3): 1013-1023.
贾瑞生, 赵同彬, 孙红梅, 等. 基于经验模态分解及独立成分分析的微震信号降噪方法 [J]. 地球物理学报, 2015, 58(3): 1013-1023.