

第 3 章

3D 数字模型的预处理

通常,由三维数字相机、三维扫描系统等数据获取设备或采用基于图像的重建方法获取的三维模型表面的采样点数据往往带有一定的噪声和失真,在对这些原始数据进行进一步几何处理之前,需要对其进行必要的预处理,主要包括点云数据的光顺去噪、配准和修复。

3.1 光顺去噪

3D 模型去噪的目的是在剔除噪声获取离散曲面更高阶光滑性的同时,保持曲面的固有几何特征,并尽量防止模型产生收缩和过光顺的现象。本节首先简述几种常用的光顺去噪方法,然后详细阐述我们提出的一种基于相似性的点模型去噪方法。

3.1.1 典型的光顺去噪方法

3D 模型光顺去噪方法较多,依据的标准不同,其分类也不同。比如,根据特征保持性和噪声在各个方向上的扩散方式,可分为各向同性算法和各向异性算法;从算法复杂性角度分类,可以分为基于 Laplace 算子的光顺方法^[7]、基于最优化的方法^[8,212]、基于组合的方法^[213,214]和非迭代的方法^[13]等。下面简要介绍几种典型的模型光顺去噪方法。

1. Laplace 方法

这是一种最常见的 3D 模型光顺算法。基本原理是对模型的每个顶点应用 Laplace 算子 $\Delta = \nabla^2 = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} + \frac{\partial^2}{\partial z^2}$,该方法将噪声扩散到顶点的相应邻域中,使模型的表面变得平滑。这种算法简单有效,但是众所周知,随着迭代次数的增加,模型体积将快速收缩。虽然提出了各种算法^[215]处理收缩问题,但是模型形态的改变是无法逆转的。

2. 平均曲率流

该算法将对模型顶点位置的调整分解为法向和切向两个正交向量^[134]。在网格顶点切平面上移动顶点达到去噪效果,在网格顶点法向上以平均曲率速度调节顶点位置能够明显改善网格局部区域以光顺网格的原理^[216],通过在网格顶点法向上以平均曲率的速度移动来达到曲面光顺的目的。Lange 等^[217]提出了点模型中基于平均曲率流的各向异性算法。Desbrun 等提出的平均曲率流采用了如下顶点估计公式:

$$M(\mathbf{p}_i) = k_H \mathbf{n}_i = -\frac{\nabla A}{2A} = -\frac{1}{4A} \sum_j (\cot \beta_{j-1} + \cot \gamma_j)(\mathbf{q}_{ij} - \mathbf{p}_i) \quad (3.1)$$

$p_i = (x_i, y_i, z_i)$ 为网格顶点, β_{j-1} 和 γ_j 在图 3.1 中定义。平均曲率流有很好的理论保证, 但是在一些特殊情况下不但起不到光顺效果, 甚至会引起网格模型的畸变; 此外该方法还有赖于对网格模型曲率的精确估计。

3. 双边滤波器

Jones 等^[13] 和 Fleishman 等^[12] 基于图像双边滤波器思想^[218], 将其推广到三维网格, 分别提出了非迭代的双边滤波算法。Jones 通过控制顶点邻接区域的大小来保持网格模型特征, 但是受到了相邻区域选择的限制。

Fleishman 通过沿顶点法向移动采样点位置来达到光顺效果, 但是容易引起过光顺而不能有效保持网格的特征。胡国飞等^[219] 同样基于图像双边滤波器的概念, 在 Jones 和 Fleishman 等方法的基础上, 基于三角网格中每个顶点的一阶邻域顶点和二阶邻域三角形, 应用带均值中心坐标权的双边滤波器和准 Laplacian 光顺算子, 通过三步预测顶点的坐标位置, 把三角网格原始顶点单步移动到预测的新坐标, 从而达到光顺网格的目的, 并保持原始三角网格的特征。

4. 其他算法

除了以上较为经典的算法, 还有很多其他的算法来解决去噪过程中遇到的各种问题。围绕着如何减少体积收缩、顶点漂移、保持几何特征等^[220] 问题展开。各种光顺算法都不同程度地改变了原模型顶点的几何位置, 而且都需要指定光顺参数来控制光顺效果和光顺程度。

3.1.2 基于相似性的点模型去噪

早期的点模型去噪算法是各向同性的, 如 Laplacian 光顺法^[221], 同样地会产生顶点漂移和过光顺现象。于是相关学者也提出了各向异性的点模型去噪算法, 如基于偏微分方程^[222] 和基于平均曲率流^[223] 的算法; 文献^[224] 提出的基于动态平衡曲率流的去噪算法防止了顶点漂移和过光顺, 然而由于强迫项的引入使算法的复杂度较高。随后, 又出现了基于 MLS 的点模型去噪算法^[225, 6, 75], 其基本思想是为点模型建立移动最小二乘逼近曲面, 通过将噪点移至所逼近的曲面上达到去噪的目的。该方法的主要问题是削弱了曲面特征。

常用的模型去噪方法并没有考虑采样点(顶点)几何特征的相似性, 这使得对具有几何特征连贯性的区域的滤波不够合理; 于是, 文献^[17] 提出了一种基于均值漂移(Mean Shift)的各向异性去噪算法, 该算法通过 Mean Shift 的迭代过程, 对点模型进行了几何特征相似性聚类并自适应地选取采样点的邻域。在这些去噪方法中, 采样点间的几何强度相似性都是仅仅通过采样点本身的几何信息来计算的, 即局部的方法。文献^[226] 提出了一种非局部的去噪算法, 即几何强度的相似性是通过比较两采样点周围区域的几何信息得到的, 然后在整个点模型上对采样点进行相似性匹配以计算该点的最终几何信息。然而, 如此的匹配计算并不是在几何特征相似的邻域中进行, 且该算法的几何信息是利用双边滤波算子求出的, 因此实质上仍属于双边滤波器去噪; 而双边滤波器去噪存在细小特征不能有效保持的不足, 如易于削弱模型的尖锐特征。




图 3.1 顶点估计公式角度标注示意图

鉴于此,我们将采样点几何强度和几何特征两方面的相似性相结合,提出一种非局部的点模型去噪算法。利用三边滤波算子计算采样点的几何强度,并通过采样点的几何强度网格估算几何强度的相似性;采用 Mean Shift 聚类法,对采样点进行几何特征相似性聚类;依据相似性,对点模型进行非局部去噪。图 3.2 展示了该算法能够有效地保持曲面细节特征的去噪效果。




图 3.2 Buste 点模型的去噪效果和平均曲率可视化

1. 非局部去噪的基本思想

Buades 等^[227]提出了一种非局部的图像去噪算法,其基本思想是:滤波后像素亮度值为邻域像素亮度值的加权平均,权值由像素邻域间的相似性决定。设图像 $\Omega = \{I(u) | u \in P\}$, 其中像素 $u = (x, y)$ 及其亮度为 $I(u)$, 则图像中各像素滤波之后的亮度值为

$$I'(u) = \frac{\sum_{v \in P} \Phi(u, v) I(v)}{\sum_{v \in P} \Phi(u, v)} \quad (3.2)$$

其中,权值 $\Phi(u, v) = \exp(-S_{u,v}/h^2)$; h 为滤波参数,控制光滑程度。像素 u 和 v 的相似度 $S_{u,v}$ 取决于分别以 u 和 v 为中心的方形邻域中对应像素亮度的相似性,即

$$S_{u,v} = \sum_o G_a(\|o\|) |I(u+o) - I(v+o)|^2 \quad (3.3)$$

o 表示邻域像素和中心像素的偏移矢量; $G_a(\cdot)$ 是标准方差为 a 的高斯核函数,邻域内相应一对像素对 $S_{u,v}$ 的贡献随偏移距离的增长而减小。于是,当 $S_{u,v}$ 较小时,即 u 和 v 的相似度较高时,其权值就较大,对式(3.2)的贡献就较大;反之贡献较小。

2. 点模型的非局部去噪算法

由于图像的采样是规则的,而点模型的采样是非规则,因此将非局部去噪方法扩展到点模型上所遇到的主要问题是如何计算采样点间的相似度。我们的策略是:通过三边滤波算子,将计算出的微分值视为图像中像素亮度的对应量,称之为采样点的“几何强度”。基于协方差分析法,在采样点的局部参考平面上构建均匀的几何强度网格,并估算采样点间几何强度的相似性。

1) 几何强度的计算

Choudhury 等设计的用于图像和网格去噪的三边滤波器^[220],亦可推广到点模型的去噪中;然而,该滤波器并没有考虑模型的曲率信息。于是,我们设计了下面的三边滤波器用于计算采样点 p_i 的几何强度 δ_i :

$$\begin{cases} \delta_i = \frac{\sum_{q_{ij} \in N(p_i)} w_{ij} \langle \mathbf{n}_i, \mathbf{q}_{ij} - \mathbf{p}_i \rangle}{\sum_{q_{ij} \in N(p_i)} w_{ij}} \\ w_{ij} = w_c(\|\mathbf{q}_{ij} - \mathbf{p}_i\|) w_s(\|\langle \mathbf{n}_i, \mathbf{q}_{ij} - \mathbf{p}_i \rangle\|) w_h(\|H_{ij} - H_i\|) \end{cases} \quad (3.4)$$

其中, $\mathbf{n}_i$ 为点 $\mathbf{p}_i$ 的法向; $N(\mathbf{p}_i)$ 是 $\mathbf{p}_i$ 的邻域; H_i 为 $\mathbf{p}_i$ 的平均曲率; $w_c(x)$ 为光顺高斯权, $w_c(x) = \exp(-x^2/2\sigma_c^2)$, σ_c 为空域上的滤波系数, 本书自适应地取 $\sigma_c = r/2$ (r 为 $N(\mathbf{p}_i)$ 的包围球半径); $w_s(x)$ 为保特征高斯权, $w_s(x) = \exp(-x^2/2\sigma_s^2)$, σ_s 为频域上的滤波系数, 本书自适应地取 σ_s 为 $\langle \mathbf{n}_i, \mathbf{q}_{ij} - \mathbf{p}_i \rangle$ 的标准差; $w_h(x)$ 为曲率变化影响权, $w_h(x) = \exp(-\exp(-\|H_{ij} - H_i\|^2/2))$, 若 $\mathbf{q}_{ij}$ 和 $\mathbf{p}_i$ 的平均曲率变化越大, 则权值越大, 以有效地光滑大噪点。

三边滤波几何强度算子不仅考虑了邻域点和该点之间的空间位置关系以及它们法向之间的关系, 还考虑了它们之间的曲率变化, 因此, 更好地反映了每个点的局部几何特征。图 3.3(b) 展示了 Face 点模型几何强度的可视化效果, 可视化时所使用的调色板如第 2 章图 2.28 所示。




图 3.3 Face 点模型的几何强度和 MS 聚类

2) 采样点间几何强度的相似性计算

我们采用第 2 章 2.4.1 节的协方差分析法建立采样点的局部坐标系, 并在 XOY 平面上构建该点的均匀几何强度网格, 由此计算出采样点间几何强度的相似性, 具体方法如下。

设采样点 $\mathbf{p}_i$ 的 R 最邻近域为 $N_R(\mathbf{p}_i)$, 其协方差矩阵的 3 个特征值为 $0 \leq \lambda_0 \leq \lambda_1 \leq \lambda_2$, 所对应的 3 个特征向量为 $\mathbf{v}_0$ 、 $\mathbf{v}_1$ 和 $\mathbf{v}_2$ 。在 $\mathbf{p}_i$ 处建立局部坐标系: 原点 O 在 $\mathbf{p}_i$ 处, 若 $\mathbf{v}_0 \cdot \mathbf{n}_i > 0$ 则 Z 轴为 $\mathbf{v}_0$, 否则 Z 轴为 $-\mathbf{v}_0$, Y 轴为 $\mathbf{v}_1$, X 轴为 $(Y \times Z)$; 设 $\mathbf{p}_j$ ($\mathbf{p}_j \in N_R(\mathbf{p}_i)$) 在该坐标系下 XOY 坐标面上投影为 $\mathbf{q}_j(u_j, v_j)$, 如图 3.4 中的灰色点所示, 其几何强度为 δ_j ; 则构建以 O 为中心的均匀几何强度网格 G_i (大小为 $M \times M$) 的过程如下:

(1) 求出 XOY 坐标面上以 O 为圆心 $\mathbf{q}_j$ 的包围圆半径 R_o , 由此可得到 G_i 的格栅间距 $h = 1.42R_o/(M-1)$;

(2) G_i 中每个格栅结点 t_{ij} 处的几何强度 δ_{ij} 通过高斯加权平均它的 k 个最邻近点 $\mathbf{q}_j$ 的几何强度获得

$$\delta_{ij} = \frac{\sum_{q_j \in N_k(t_{ij})} w_g(\mathbf{q}_j) \cdot \delta_j}{\sum_{q_j \in N_k(t_{ij})} w_g(\mathbf{q}_j)} \quad (3.5)$$

其中, $w_g(\mathbf{q}_j) = \exp(-\|\mathbf{q}_j - t_{ij}\|^2/(2\sigma_g^2))$, 本书自适应地




图 3.4 均匀几何强度网格 G_i 的构建

取 $\sigma_g = R_o/2$; 取 k 为 9, M 为 5、7 或 9, $R = 0.71M |E| \left(|E| = \frac{1}{n} \sum_{i=0}^{n-1} r_{i\min}, r_{i\min} \text{ 为 } p_i \text{ 和其最近点间的距离} \right)$ 。显然, 若存在 q_j 刚好位于 t_{ij} , 则 t_{ij} 的几何强度为 δ_j 。

通过上述方法, 采样点的均匀几何强度网格 G_i 被成功地构建; 将 G_i 视为 2D 图像中像素方形邻域的对对应量, 由式(3.3)求出采样点间几何强度的相似性。

3) 点模型的几何特征相似性聚类

该非局部去噪并不是在整个点模型上求加权和以得到 p_i 滤波后的几何强度, 而是在和 p_i 具有相似几何特征的聚类(邻域)上进行的; 我们通过 Mean Shift 聚类法得到点模型的几何特征相似性聚类。Mean Shift 是一种基于多模特征空间分析的一般性非参数技术^[228], 已广泛应用于计算机视觉与模式识别等领域, 如目标跟踪^[229]、图像分割^[230]、聚类分析^[231]和特征空间分析^[228]等; 最近, 文献[17]、[232]和[233]将其推广到 3D 模型的数字几何处理领域。下面对 Mean Shift 算法作简要的介绍。

给定 d 维欧式空间 R^d 中的一个点集 $S = \{x_1, x_2, \dots, x_n\}$, 点 x 处的多元核密度估计函数为^[231, 232]

$$f(x) = \frac{1}{nh_i^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h_i}\right) \quad (3.6)$$

其中, $h_i > 0$ 称为带宽, 表明在多大的 x 邻域内估计 x 点处的密度; $K(x) = c_{k,d} k(\|x\|^2)$ 被称为密度核函数($c_{k,d}$ 为归一化常量), $k(x)$ 被称为轮廓函数。对式(3.6)进行微分可以得到 x 处的梯度:

$$M_G(x) = \frac{\sum_{i=1}^n \frac{x_i}{h_i^{d+2}} g\left(\left\|\frac{x - x_i}{h_i}\right\|^2\right)}{\sum_{i=1}^n \frac{1}{h_i^{d+2}} g\left(\left\|\frac{x - x_i}{h_i}\right\|^2\right)} - x \quad (3.7)$$

其中, $g(x) = -K'(x)$, 本书取高斯核函数。式(3.7)表明, 如果要将 x 向带宽 h_i 范围内密度最大的地方移动, 则沿 $M_G(x)$ (即 MS 迭代向量) 方向移动是最快的; 如此不断迭代的过程在理论上已被证明是收敛的^[234, 235], 即

$$y_k^{[j+1]} = \frac{\sum_{i=1}^n \frac{x_i}{h_i^{d+2}} g\left(\left\|\frac{y_k^{[j]} - x_i}{h_i}\right\|^2\right)}{\sum_{i=1}^n \frac{1}{h_i^{d+2}} g\left(\left\|\frac{y_k^{[j]} - x_i}{h_i}\right\|^2\right)}, \quad k \in [1, n], j = 0, 1, 2, \dots \quad (3.8)$$

收敛于最近的局部模式点(即密度估计的局部最大值点), 具体过程见算法 3.1。由此, 在多维的变量空间中, Mean Shift 算法将所有对指定特征具有相同局部模式的元素点(即具有局部相似性的元素点)界定在同一个区域(即类簇)中。

算法 3.1 Mean Shift 迭代算法。

- (1) 设置初始值 $y_k^{[0]}$ 为 x_k , 结束条件为 ϵ ;
- (2) 由式(3.8)计算 $y_k^{[j+1]}$ 的值;
- (3) 若 $|y_k^{[j+1]} - y_k^{[j]}| \leq \epsilon$ 成立, 则退出; 否则 $y_k^{[j]} \leftarrow y_k^{[j+1]}$, 转至(2)。

在进行 Mean Shift 聚类时, 不仅考虑采样点 p_i 的空间位置, 而且也考虑 p_i 的法向 n_i 和曲率 H_i , p_i 被描述为 7 维特征空间中的一个向量 $\bar{p}_i = (x_i, y_i, z_i, n_{x_i}, n_{y_i}, n_{z_i}, H_i)$, 点模型

P_n 为 R^7 中的一个点集 $\bar{P}_n = \{\bar{p}_0, \bar{p}_1, \dots, \bar{p}_{n-1}\}$ 。对 $\bar{P}_n$ 执行 Mean Shift 算法, 将使 $\bar{p}_i$ 收敛到最近的局部模式点 $\bar{p}_m$, 所有收敛于 $\bar{p}_m$ 的采样点聚为一类; 于是, Mean Shift 算法在指定的特征空间中将整个点模型按照局部模式点进行划分。因此, 本节的 Mean Shift 聚类依据的是采样点的空间位置、法向和曲率的邻近性, 故实现了点模型表面区域几何特征相似性聚类。

在具体的迭代过程中, 可由 k - d 树搜索 $N(\mathbf{p}_i)^{[236]}$, 然后将 $N(\mathbf{p}_i)$ 中满足法向和曲率要求的邻域点 $N'(\mathbf{p}_i)$ 用于 $\mathbf{y}_k^{[j+1]}$ 的求解, 同时由 $N'(\mathbf{p}_i)$ 自适应地决定带宽 h_i 。图 3.3(c) 展示了本节对 Face 点模型的 Mean Shift 聚类结果, 图 3.3(d) 为其局部模式点集。

4) 点模型的非局部去噪

根据 $\mathbf{p}_i$ 和 $\mathbf{p}_i$ 所在聚类 $C(\mathbf{p}_i)$ 中采样点的几何强度相似性, 由式 (3.2) 计算出 $\mathbf{p}_i$ 的最终几何强度 δ'_i :

$$\delta'_i = \frac{\sum_{\mathbf{q}_{ij} \in C(\mathbf{p}_i)} \Phi(\mathbf{p}_i, \mathbf{q}_{ij}) \delta_{ij}}{\sum_{\mathbf{q}_{ij} \in C(\mathbf{p}_i)} \Phi(\mathbf{p}_i, \mathbf{q}_{ij})}$$

其中, $\Phi(\mathbf{p}_i, \mathbf{q}_{ij}) = \exp(-S_{\mathbf{p}_i, \mathbf{q}_{ij}}/h^2)$, $S_{\mathbf{p}_i, \mathbf{q}_{ij}}$ 通过 $\mathbf{p}_i$ 与 $\mathbf{q}_{ij}$ 各自的几何强度网格由式 (3.3) 求出。得到 δ'_i 后, 沿 $\mathbf{p}_i$ 的法向移动, 即可得到 $\mathbf{p}_i$ 光顺后的几何坐标 $\mathbf{p}'_i = \mathbf{p}_i + \delta'_i \mathbf{n}_i$ 。

由于该方法是沿法向移动采样点, 因此有效地避免了顶点漂移的现象。更重要的是, 该方法不仅考虑了采样点间几何特征的相似性, 而且也考虑了采样点间几何强度的相似性; 因此该方法较基于空间邻域的局部滤波算子更加鲁棒。

3. 实验结果与讨论

我们在 Pentium4 2.8GHz CPU、1GB 内存的 PC 上实现了本节介绍的算法 (NLD), 并与双边滤波器 (BIL)、Mean Shift (MST) 去噪算法进行了光顺比较。Face、Gargo 和 Buste 三个噪声模型的去噪结果比较如图 3.5、图 3.6 和图 3.7 所示。在表 3.1 中列出了 3 种去噪算法相关参数的设置和相应的实验统计量。




图 3.5 Face 噪声模型去噪结果的比较




图 3.6 Gargo 噪声模型去噪结果的比较

表 3.1 3 种去噪算法相关参数的设置和相应的实验统计量

图号	Method	Iters.	Sim.	k	Max. Error(10^{-4})	Ave. Error(10^{-4})	T_{MS}/s	T_D/s
图 3.5	BIL	1	—	15	89.3	4.5	—	0.33
	MST	1	—	15	51.9	3.3	15.1	3.52
	NLD	1	5×5	15	31.3	2.4		15.31
图 3.6	BIL	3	—	20	78.3	15.8	—	1.11
	MST	4	—	20	79.8	15.4	73.06	13.46
	NLD	4	9×9	20	75.4	14.2		110.59
图 3.7	BIL	3	—	23	131.7	19.5	—	1.33
	MST	3	—	23	96.5	16.8	98.7	14.02
	NLD	3	9×9	23	74.2	13.3		148.58

注: Iters. 为迭代次数,通过平均曲率可视化效果最佳来确定;Sim. 为相似性比较时 Grid 的尺寸; k 为去噪时采样点的邻域大小(BIL),在 Mean Shift 聚类时 k 为采样点初始窗口中的采样点数;Max. Error 为顶点偏移的最大距离,Ave. Error 为顶点偏移的平均距离; T_{MS} 为 Mean Shift 聚类时间; T_D 为迭代一次的顶点滤波时间。

图 3.5 给出了 3 种算法对 Face 噪声模型^①(采样点数为 34308),去噪结果的比较,图 3.5 中上面 3 个图为去噪模型的点绘制图,下面 3 个图为相应模型的平均曲率可视化效果。图 3.6(a)为 Gargo 噪声模型(点数为 101557,通过加入 15%的高斯噪声($\mu=0, \sigma=0.36|E|$)获得);图 3.6(b)~(d)左图给出了去噪结果的比较,图 3.6(b)~(d)右图为相应模型的平均曲率可视化效果图。从图 3.5 和图 3.6 可以看出,NLD 算法较 BIL 和 MST 更有效地保持了曲面的细节特征,如在 Face 模型的眉毛和眼睛等处以及 Gargo 模型的眼睛和羽毛等处,NLD 算法表现得更为丰富。

前面的图 3.2 给出 NLD 算法光滑 Buste 噪声模型的有效性,该噪声模型(点数为 125813)通过加入 15%的高斯噪声($\mu=0, \sigma=0.3|E|$)而获得,并在图 3.7 中给出了 3 种算法对其去噪结果的比较。图 3.7 中上面 3 个图为 3 种算法光滑后的点模型平均曲率可视化效果图,可以看出 NLD 算法较 BIL 和 MST 更有效地保持了细节特征;图 3.7 中下面 3 个图为 3 种算法去噪后的点模型顶点偏移距离可视化效果图,可以看出 NLD 算法产生的过光滑最低,即在 3 种算法中顶点平均偏移距离最小,表 3.1 中列出的误差统计数据也证实了这一点。由于 NLD 算法需要构建采样点的几何强度网格以及需要计算采样点间的相似度,因此在执行速度上慢于 BIL 和 MST。




图 3.7 Buste 噪声模型去噪结果的比较

3.2 配准

在扫描 3D 实体时,由于受到测量设备和环境的限制,物体表面完整测量数据的获得往往需要通过多次测量完成。由于每次测量得到的点云数据往往只覆盖物体部分表面,并且可能出现平移错位和旋转错位,因此需要对这些局部点云数据进行整合和配准^[19,20],以得到完整的三维模型点云数据。本节首先概述点云的配准方法,然后详细阐述我们课题组所

^① 该噪声模型由 Yutake Ohtake 提供。

提出的一种基于 ICP 算法的点云配准方法^[237]。

3.2.1 引言

点云配准有手动配准、依赖仪器的配准和自动配准 3 种,通常所说的点云配准技术即是指最后一种。点云自动配准技术是通过一定的算法或统计学规律,利用计算机计算两片点云之间的错位,从而达到把两片点云自动配准的效果。目前采用的自动配准技术一般分为初始配准和精确配准两步,初始配准是为了缩小点云之间的旋转和平移错位以提高精确配准的效率和趋向,精确配准则是为了使两个点云之间的配准误差达到最小。

精确配准一般采用 ICP(Iterative Closest Point)算法^[23],但传统的 ICP 算法计算效率不高,因此国内外许多研究者都为改进 ICP 算法做出了努力。Chen 等^[238]提出了用点的切平面来逼近点云,最后归结为求点到切平面的最小二乘距离的方法,但这种方法速度仍然比较慢。Blais 等^[239]结合了逆向定标法和随机搜寻法来提高速度,但会对配准精度产生一定的影响。Li 等^[240]提出了一种 ICL(Iterative Closest Line)算法,通过直接对两个点云中的点连线并寻找对应线段进行配准,但存在无法保证线段之间的对应关系的缺陷。张等^[241]提出用扰动平移矩阵法加快收敛速度,但该方法只能对某些模型有较明显的效果。

常见的初始配准的方法有以下 3 类:中心重合法^[241],简单地把两个点云的重心重合,这种方式只能缩小平移错位而无法缩小旋转错位;标签法^[21,242],即在测量时人为地贴上一些特征点,然后使用这些特征点进行定位,这种方式仍然是依赖于测量和仪器的;提取特征法,有提取平面特征^[243]和提取轮廓曲线^[22]等,这种方式要求点云有比较明显的特征。

3.2.2 基于 ICP 算法的点云配准

通过上述分析,本课题组对 ICP 算法进行了如下改进:

(1) 对于点云初始配准,提出了一种新的主方向贴合法,能够快速缩小平移和旋转错位,并且对仪器和点云都没有特殊要求,具有广泛的适用性。

(2) 对于精确配准,改进了 ICP 算法,提出了一种基于特征点的 ICP 算法。通过计算曲率特征提取点云特征点,并使用 $k-d$ 树搜寻最近点,大大提高了算法效率,尤其适用于海量数据的计算,具有良好的收敛速度和配准精度。

1. 点云初始配准

为了缩小点云之间的旋转和平移错位,使得精确配准不致趋向错误的方向,需要进行点云初始配准。本章利用点云主方向贴合法实现自动初始配准,具有方便、快捷、精确的效果。

每个点云都存在一个空间上的主方向,这个主方向可由计算点云中所有点的特征向量得到,根据特征向量还可以得到与主方向垂直的两个次方向。由此可建立一个以点云重心为原点,以点云主方向以及次方向为坐标轴的一个参考坐标系。这样,对于相似度大的两个点云,只要把两个参考坐标系调整为一致,即可以实现点云配准。对于差异较大的点云,通过这种方式,也可以达到缩小点云之间错位的目的。

由于主方向具有正反两个方向,因此有可能出现配准后两个点云正好相差 180° 的情况,所以配准后还需测试是否出现这种情况。本章通过计算两个点云的包围盒来测试两个点云是否重合。设 V_r 为参考点云包围盒体积, V_d 为目标点云包围盒体积, V_i 为参考点云

和目标点云包围盒相交得到的包围盒的体积。则包围盒重合系数 $f=(V_i \times V_j)/(V_r \times V_d)$, 如果 $f>T$, T 为设定值, 则两个点云大致重合。否则两个点云不重合, 应反转参考坐标系的 X 轴或 Y 轴再次测试。如果 4 种可能性都测试过, 并且没有任何一个 f 大于 T , 则说明两个点云差异较大, 取 f 最大的那种即可。算法流程如下:

Step 1: 读取参考点云和目标点云;

Step 2: 分别粗略选取两片点云可以重叠的部分;

Step 3: 分别用雅克比法计算选取区域的特征向量和特征值, 按特征值从大到小排列特征向量为 EV_0 、 EV_1 、 EV_2 ;

Step 4: 分别计算点云重心 C , 以 C 为原点, 以 EV_0 为 X 轴, EV_1 为 Y 轴, $EV_0 \times EV_1$ 为 Z 轴, 建立参考坐标系;

Step 5: 由两个坐标系计算得到坐标变换矩阵;

Step 6: 根据坐标变换矩阵变换目标点云坐标;

Step 7: 测试变换后点云和参考点云是否大致重合, 不重合则反转目标点云的 X 轴或 Y 轴, 跳到 Step 5;

Step 8: 点云重合, 结束。

2. 点云精确配准

为了尽可能配准两个点云, 使它们之间的误差最小, 还需在初始配准的基础上进行自动精确配准。本课题组采用基于特征点的 ICP 算法进行精确配准, 该算法可以有效地提高计算速度, 对于海量数据点云效果十分显著, 可以有效地缩短原 ICP 算法的计算时间。在研究 ICP 算法之前, 必须先了解其中所使用的一个关键算法, 即对应点集配准算法 (Corresponding Point Set Registration)。

1) 对应点集配准的单位四元数法

对应点集配准算法的目标在于寻找最小二乘逼近的坐标变换矩阵, 对于互相对应的两个点集, 可以采用单位四元数法^[23]得到。

若目标点集 P 对应于参考点集 X , 对应点集应满足以下条件:

(1) P 中点的个数 N_P 和 X 中点的个数 N_X 相等, 即 $N_P=N_X$;

(2) 对于 P 中每一个点 $\vec{p}_i$ 都应该对应于 X 中具有相同下标的 $\vec{x}_i$, 即 $\vec{p}_i=\vec{x}_i$ 。设旋转变换向量为单位四元数 $\vec{q}_R=[q_0 q_1 q_2 q_3]^t$, 其中 $q_0 \geq 0$ 且 $q_0^2+q_1^2+q_2^2+q_3^2=1$, 可得 3×3 旋转矩阵 $R(\vec{q}_R)$ 。设平移变换向量为 $\vec{q}_T=[q_4 q_5 q_6]^t$, 可得完全坐标变换向量 $\vec{q}=[\vec{q}_R | \vec{q}_T]^t$ 。则求对应点集间的最佳坐标变换向量问题可转化为求 $\vec{q}$ 使得函数 $f(\vec{q})=\frac{1}{N_P} \sum_{i=1}^{N_P} \|\vec{x}_i-R(\vec{q}_R) \vec{p}_i-$

$\vec{q}_T\|^2$ 最小化的问题。算法流程如下:

Step 1: 得到对应点集 P 和 X ;

Step 2: 计算目标点集 P 的重心和参考点集 X 的重心:

$$\vec{\mu}_p = \frac{1}{N_p} \sum_{i=1}^{N_p} \vec{p}_i, \quad \vec{\mu}_x = \frac{1}{N_x} \sum_{i=1}^{N_x} \vec{x}_i$$