

点云粒子滤波贝叶斯重构

冯肖维, 赵一平, 陈信钰, 王锡淮

(上海海事大学电气自动化系 上海 201306)
(xwfeng@shmtu.edu.cn)

摘要: 针对三维点云重构过程中由于过度平滑和锐化造成的特征失真问题, 提出一种具有特征保持的概率重构算法. 首先利用空间主成分分析进行点云局部曲率的低秩估计, 辨识尖锐特征, 并根据曲率对法向场进行自适应优化, 以保证尖锐特征恢复时能够获得准确的法向约束; 然后依据贝叶斯统计推论建立点云最大后验概率重构模型, 并设计了粒子滤波器对各点位置的后验概率分布进行序贯蒙特卡罗模拟; 为了提高算法的收敛速度, 根据局部噪声强弱自适应地调整粒子重采样范围; 最后针对点云不同区域分别使用法向与球体重采样完成多假设检验重构, 解决特征退化和边缘不规整的问题. 与多种典型算法的对比实验结果表明, 所提算法在主观视觉效果、重构精度和效率方面均有改善, 重构精度与时效分别平均提高 46.84% 和 33.34%; 该算法在抑制噪声的同时, 能够有效地恢复原有特征, 提高了点云质量.

关键词: 点云重构; 贝叶斯估计; 粒子滤波; 法向估计; 多假设检验
中图分类号: TP391.41 **DOI:** 10.3724/SP.J.1089.2023-00810

Point Cloud Bayesian Reconstruction Based on Particle Filtering

Feng Xiaowei, Zhao Yiping, Chen Xinyu, and Wang Xihuai

(Department of Electrical Automation, Shanghai Maritime University, Shanghai 201306)

Abstract: To solve the problem of feature distortion induced by excessive smoothing or sharpening during the reconstruction of 3D point cloud, a feature-preserving probabilistic reconstruction method is proposed. First, low-rank estimation of local curvature of point cloud is realized by space-based principal component analysis in order to better locate sharp features, and the normal field of point cloud is adaptively optimized based on curvature which guarantees accurate normal constraints during sharp feature recovery. Then, the probability reconstruction model of point cloud is established according to Bayesian statistic inference. And the posterior probability distribution of each point position is simulated by sequential Monte Carlo method within particle filtering framework. In order to improve the convergence, the resampling range is adjusted according to the local noise. Finally, the Bayesian reconstruction of point cloud is achieved using resampling with normal and spherical constraints for different regions which takes the advantage of multiple hypothesis testing, and the problems of feature degradation and irregular edges are solved. Compared with several state-of-the-art methods, the experimental results show that the proposed algorithm has improved subjective visual effects, reconstruction accuracy, and efficiency, and the reconstruction error is reduced by 46.84% while the running time is decreased by 33.34% on average. The proposed method can effectively restore original features while suppressing noise, which improve the quality of point cloud.

收稿日期: 2023-12-19; 修回日期: 2024-09-05. 基金项目: 上海市科委重点项目(Z20218044). 冯肖维(1982—), 男, 博士, 讲师, 硕士生导师, 主要研究方向为计算机图形学、机器视觉、机器人导航; 赵一平(1999—), 男, 硕士研究生, 主要研究方向为计算机图形学; 陈信钰(1999—), 男, 硕士研究生, 主要研究方向为计算机图形学; 王锡淮(1961—), 男, 博士, 教授, 主要研究方向为信号处理、系统建模与优化.

Key words: point cloud reconstruction; Bayesian estimation; particle filtering; normal estimation; multiple hypothesis testing

近年来, 点云作为现实对象数字化表示的有效方法, 被广泛应用于逆向工程、自动驾驶、地理信息系统等领域, 并得到大量关注^[1-4]. 受限于各种测量设备, 如三维激光雷达、立体视觉系统等固有的缺陷, 所采集到的点云不可避免地存在噪声和畸变. 因此, 需要对原始点云进行重构——降噪与特征恢复.

由于点云是一种含有随机和干扰噪声的离散信号, 因此概率统计算法被广泛应用于点云重构. 假设隐含曲面局部光滑, 点云可以利用移动最小二乘(moving least squares, MLS)投影至局部拟合平面进行降噪^[5-7]. 然而该类统计估计算法对离群噪声较为敏感, 且其所具有的低通滤波特性会使尖锐特征收缩变形. 考虑尖锐特征处具有分段平滑的特点, Fleishman 等^[8]提出迭代重拟合算法, 使用前向搜索对跨越曲面不连续处的点集进行统计评估, 排除离群点; 但是其需要密集的点云数据, 并且由于缺乏全局分类的一致性, 尖锐特征处容易出现交叉伪影. 为了进一步提高抗干扰能力, Öztireli 等^[9]结合隐式 MLS 和局部核回归提出鲁棒隐式移动最小二乘法(robust implicit moving least squares, RIMLS)算法, 可以处理稀疏点云模型, 在更好地保留原有信息的同时生成连续曲面, 但其对尖锐特征的恢复能力较弱. 概率模型可以有效地描述随机变量, 并用于估计其统计特征. 因此, Jenke 等^[10]将点云的测量过程和先验信息进行概率建模, 利用贝叶斯统计推论将点云重构表示为最大后验概率(maximum a posteriori, MAP)问题, 并借助先验信息获得光滑、均匀和特征清晰的重构结果; 但是, 其中的目标函数需要进行局部线性化, 并附加烦琐的尺度参数与正则项系数的调整.

根据统计学习中 L_1 -median 优化对离群点不敏感的特点, Lipman 等^[11]提出局部最优投影(locally optimal projector, LOP)以及 Huang 等^[12]提出边缘感知重采样(edge-aware resampling, EAR), 它无需法向信息, 通过一阶近似即可得到优化重构的迭代闭解, 计算简便; 但是, 该类算法需要进行烦琐的尺度参数调整, 当点云数量庞大时计算较为耗时. 为了提高算法的时效, Preiner 等^[13]提出连续局部最优投影(continuous locally optimal projector, CLOP)算法, 利用高斯混合模型(gaussian mixture model, GMM)估计点分布的概率密度, 在此基础

上, 使用期望最大化(expectation maximum, EM)进行概率重构; 但是, 由于该算法没有考虑点云的任何先验信息(如法向), 因此处理后点云的光顺性并不理想. 为此, Lu 等^[14]在 CLOP 的基础上引入法向约束, 将 LOP 中的 L_1 -median 优化转变为基于平面投影的二次优化, 改善了投影后点云的光顺性; 但其未考虑尖锐特征的恢复.

点云中的尖锐特征在数量上要远小于噪声^[15]. 针对尖锐特征的稀疏性, Cheng 等^[16]将压缩感知中的 L_0 稀疏建模扩展到点云重构中, 通过增加权重和正则项实现具有密度调整的点云稀疏重采样; 但是, 点云隐含曲面容易退化成分段平面, 产生冗余边缘特征. 与稀疏建模类似的另一类算法是低秩建模^[17]. Lu 等^[18]利用点云法向场局部结构相似性进行法向低秩估计, 配合双投影误差优化实现点云降噪; 但是, 稀疏和低秩建模算法需要进行组合优化, 求解过程复杂.

基于深度学习的算法, 尤其是卷积神经网络(convolutional neural network, CNN)技术在点云数据降噪处理方面吸引了研究人员的大量关注^[19]. 基于卷积的架构, Roveri 等^[20]提出 PointProNet, 将局部点云转换为规则采样的高度图, 有效地利用图像卷积去噪的整体框架; 但在利用法向构建局部坐标系时, 容易受到噪声和异常值的影响. Rakotosaona 等^[21]基于分块卷积神经网络(patch-based convolutional neural networks, PCPNet)设计一种两阶段点云降噪网络 PointCleanNet, 可以稳健地估计局部特征, 并对点云进行去噪处理; 但由于没有考虑补片区域的局部几何结构, 因此难以捕捉噪声和异常值. 为此, Nakayama 等^[22]设计 2 种动态图卷积层, 以解决 PointCleanNet 不考虑补片中邻近点之间关联性的问题. 但是, 深度学习是一种基于数据驱动的方法, 需要大量的样本来学习和验证模型参数.

1 本文算法概述

为了在抑制噪声的同时尽可能地保留尖锐特征, 本文提出基于粒子滤波的点云概率重构算法. (1) 为了准确地估计噪声引起的法向扰动和曲面特征固有的法向变化, 通过空间主成分分析(principal component analysis, PCA)完成点云局部曲率低秩

估计,并根据局部曲率自适应地调整法向优化的尺度参数,使尖锐特征处的法向与构成该特征的某个邻域面保持一致,提高尖锐特征辨识和重构的准确性;(2)针对点云噪声的随机性对其测量过程进行概率建模,并利用贝叶斯推论对点云进行

MAP 重构;(3) 为了提高计算效率同时减小重构误差,设计具有几何约束的自适应重采样粒子滤波器,其中的多假设检验机制可以解决点云重构过程中噪声和离群点引起的特征失真问题. 本文算法总体流程如图 1 所示.




图 1 本文算法总体流程

2 特征辨识

原始点云包含的噪声和尖锐特征有时难以区分,为了在抑制噪声的同时尽可能地保留尖锐特征,需要进行特征识别.

2.1 特征点曲率估计

为了识别点云中曲率较大的特征区域,本文通过空间 PCA 计算每个点局部邻域投票张量矩阵的特征值,并以此估计该点处隐含面的曲率,完成特征点的初步辨识^[23-24].

原始点云 $P = \{v_i | v_i = s_i + g\}_{i=1}^N$ 由三维空间中 N 个含有随机噪声 g 的点 $v_i \in \mathbb{R}^{3 \times 1}$ 构成, $s_i \in \mathbb{R}^{3 \times 1}$ 表示 v_i 的理想坐标. v_i 的 m 个邻近点可以构成半径 δ 的局部球邻域 $\Omega = \{v_j | v_j \in P \cap \|v_j - v_i\| < \delta\}_{j=1}^m$, 其中, $\|\cdot\|$ 表示向量二范数,则邻域 Ω 的空间投票张量矩阵可以表示为

$$T_i = \frac{1}{m} \sum_{j=1}^m (v_j - \bar{v}_i) \cdot (v_j - \bar{v}_i)^T.$$

其中, $\bar{v}_i = \left(\sum_{j=1}^m v_j \right) / m$ 表示邻域内所有点的平均坐标.

由于矩阵 T_i 是对称半正定的,因此特征向量张成隐含流形面的局部切空间,对应的特征值表示邻域点的分布范围,即邻域点最小长方体包围盒的大小. 则点 v_i 处的曲率可以近似为

$$\rho_i = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2}.$$

其中, $0 \leq \lambda_0 \leq \lambda_1 \leq \lambda_2$ 表示矩阵 T_i 的特征值. ρ_i 反映 v_i 点所在局部邻域隐含面的弯曲程度,其值越大,说明隐含面越不平坦,具有较大曲率. 通过设置阈值 θ ,可以初步辨识具有较大曲率的特征

点 $\{v_i | \rho_i > \theta\}$, 取经验值 $\theta = 0.05$.

2.2 尖锐特征识别

本文中的法向优化算法能使尖锐特征点的法向与构成特征的某个邻域面的法向保持一致,此时,法向间的夹角即为组成该尖锐特征的邻域面间的夹角. 因此,可以根据法向变化进一步辨识尖锐特征点,公式为

$$\kappa_i = \begin{cases} 0, & \text{if } \|n_j - n_i\| > \tau \\ 1, & \text{otherwise} \end{cases}.$$

其中, $n_i \in \mathbb{R}^{3 \times 1}$ 表示点 v_i 的单位法向; n_j 表示 v_i 邻域点 v_j 的单位法向; τ 表示面法向夹角阈值,取经验值 $\sqrt{2}$.

3 法向自适应估计

法向是曲面流形的一阶几何特征,对点云的降噪与特征恢复至关重要^[25]. 基于最小平方误差的法向拟合算法可以有效地估计点云平滑区域的法向,但是在尖锐特征处,原始点云容易存在各向异性采样,且邻域点可能来自不同邻接曲面;因此各向同性地对待所有邻域点会导致法向估计产生误差.

准确地估计点云尖锐特征处法向的关键是保证邻域点来自同一流形. Mederos 等^[26]提出加权拟合法向优化算法,利用 PCA 估计法向初值;然后根据邻域点 v_j 到待估计点 v_i 的距离,以及 v_j 到点 v_i 所在局部邻域拟合平面的投影误差 $e_j^n = n_i \cdot (v_j - v_i)$,判断邻域点 v_j 与点 v_i 是否属于相同流形面,从而保证参与法向估计的邻域点尽可能属于同一流形面,避免离群点的干扰.

通常, 属于同一流形面的邻近法向也是相近的. 为了更加准确地辨识邻域点, Wang 等^[27]在 Mederos 算法的基础上引入法向相似性权重, 使得与当前点具有相近法向的邻域点在法向优化中起主导作用, 公式为

$$\hat{n}_i = \arg \min_{n_i} \sum_{j=1}^m \omega_i^d(v_j) \cdot \omega_i^e(e_j^n) \cdot \omega_i^n(n_j) \cdot (e_j^n)^2.$$

其中, $\omega_i^d(v_j) = \exp(-\|v_i - v_j\|^2 / (\sigma_i^d)^2)$ 表示距离权重; $\omega_i^e(e_j^n) = \exp(-(e_j^n)^2 / (\sigma_i^e)^2)$ 表示投影误差权重; $\omega_i^n(n_j) = \exp(-\|n_i - n_j\|^2 / (\sigma_i^n)^2)$ 表示法向变化权重; σ_i^d , σ_i^e 和 σ_i^n 分别表示距离、投影误差和法向变化尺度参数, 用于控制对应权重的变化率. 由于点云固有噪声的影响, 属于同一邻域面的初始法向可能存在较大的变化, 因此给基于法向相似性的邻域判断造成困难. 为此, 针对平面和棱边特征为主的点云模型, Liu 等^[23]通过调整尺度参数避免法向由于噪声扰动而造成邻域的误判, 但对于具有一定曲率的曲面模型, 固定的尺度参数难以辨识噪声引起的法向扰动和曲面特征固有的法向变化, 使用中有一定的局限性.

为了增加邻域估计的准确性, 本文根据局部曲率自适应地调整尺度参数

$$\begin{cases} \sigma_i^d = \delta \\ \sigma_i^e = e_{\max}^n \cdot \rho_i / 3\theta \\ \sigma_i^n = \|n_j - n_i\|_{\max} \cdot \rho_i / 3\theta \end{cases}.$$

其中, $e_{\max}^n$ 表示邻域点到拟合平面的最大投影误差; $\|n_j - n_i\|_{\max}$ 表示待估计点法向与其邻域点法向间的最大变化量. 当特征曲率变大时, 投影误差尺度 σ_i^e 和法向变化尺度 σ_i^n 减小, 使得具有较大拟合误差与法向变化的邻域点的权重变小, 从而减小非一致邻域点的影响, 并在优化时增加特征处法向调整量, 使尖锐特征两侧法向变得更加分明; 反之, 对于平坦区域减小法向调整量, 法向缓慢发生变化. 由于特征阈值 $\theta < 1$ 会增加权重的尺度, 导致式(4)忽略一些细微特征, 因此本文将尺度缩小一个固定倍数, 增加特征阈值 θ 对于邻域点辨识的灵敏度.

4 点云贝叶斯重构

4.1 贝叶斯统计推论

贝叶斯推论根据含有噪声的实际测量数据

$y_{1:k-1}$ 对目标状态 x_k 进行估计, 通过预测和更新不断迭代使得估计值接近真实值. 其中, 利用建立的状态转移模型 $p(x_k | x_{k-1})$ 进行预测, 通过当前状态 $p(x_{k-1} | y_{k-1})$ 对下一时刻状态进行预测, 得到先验概率密度

$$p(x_k | y_{k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | y_{k-1}) dx_{k-1}.$$

更新则是利用观测模型 $p(y_k | x_k)$ 和当前的测量值 y_k 对先验概率密度进行修正, 得到后验概率密度

$$p(x_k | y_{1:k}) = \frac{p(y_k | x_k) p(x_k | y_{k-1})}{\int p(y_k | x_k) p(x_k | y_{k-1}) dx_k}.$$

4.2 概率重构模型

通过某种方式从目标表面采集到含有噪声的点云为 P , 并假设各点是局部独立测量, 即点 v_i 只与邻域点集 Ω_i 产生关联. 如果可以建立一个解析的观测模型 $p(\Omega_i | v_i)$, 即点 v_i 所在局部隐含曲面经过测量得到邻域点集 Ω_i 的似然函数, 那么在已知某点 v_i 先验概率分布 $p(v_i)$ 的情况下, 可以利用贝叶斯定理恢复该点测量的逆过程^[10], 即在已知邻域点集 Ω_i 的情况下, 点 v_i 位置的后验概率为

$$p(v_i | \Omega_i) = \frac{p(\Omega_i | v_i) \cdot p(v_i)}{p(\Omega_i)} = \frac{p(\Omega_i | v_i) \cdot p(v_i)}{\int p(\Omega_i | v_i) \cdot p(v_i) \cdot dv_i} \quad (1)$$

(1) 将式(1)看作点的随机过程, 如果已知 $k-1$ 时刻点 v_i 位置状态的条件概率 $p(v_{i,k-1} | \Omega_{i,1:k-1})$, 则 k 时刻在一阶马尔可夫条件下, 点 v_i 位置的概率可以预测为

$$p(v_{i,k} | \Omega_{i,1:k-1}) = \int p(v_{i,k} | v_{i,k-1}) \cdot p(v_{i,k-1} | \Omega_{i,1:k-1}) \cdot dv_{i,k-1} \quad (2)$$

其中, $p(v_{i,k} | v_{i,k-1})$ 表示状态转移概率, 本文取高斯过程模型. 同时, 将 $k-1$ 时刻重构的点集作为 k 时刻的邻域点集 $\Omega_{i,k} = \{\hat{v}_{i,k-1}\}$, $\Omega_{i,0}$ 取原始点云数据.

(2) 根据贝叶斯定理对式(2)进行更新, 得到 k 时刻点 v_i 位置状态的后验概率

$$p(v_{i,k} | \Omega_{i,1:k}) = \frac{p(\Omega_{i,k} | v_{i,k}) \cdot p(v_{i,k} | \Omega_{i,1:k-1})}{\int p(\Omega_{i,k} | v_{i,k}) \cdot p(v_{i,k} | \Omega_{i,1:k-1}) \cdot dv_{i,k}} \quad (3)$$

(3) 对式(3)进行 MAP 估计, 即可以得到重构后的 v_i 点为

$$\hat{v}_{i,k} = \arg \max_{v_{i,k}} (p(v_{i,k} | \Omega_{i,1:k})) \quad (4)$$

在高斯噪声的假设下, 式(4)的求解可以转换为二次规划问题, 选取约束条件添加为正则项, 并将问题线性化后, 采用梯度下降法进行数值求解^[10]. 受到优化初值的影响, 噪声较大时前述算法容易陷入局部极值, 并且当噪声为非高斯或目标函数难以线性化时, 该算法不再适用. 为此, 借鉴文献[28]的观点——逼近一个概率分布比逼近一个非线性函数或变换更有效, 本文通过蒙特卡罗模拟直接估计各点位置的概率分布 $p(\mathbf{v}_{i,k}|\Omega_{i,1:k})$, 并在粒子滤波框架下完成点云重构, 避免问题求解过程中的局部线性化, 在提高计算效率的同时减小近似误差; 此外, 该算法具有的多假设检验机制可以防止算法由于强噪声或离群点的干扰而陷入局部极值, 具有较好的稳定性.

4.3 点云粒子滤波

粒子滤波利用蒙特卡罗模拟实现贝叶斯估计, 通过一组带有权值 $\omega_{i,k}^{(u)}$ 的随机样本粒子 $\chi_{i,k}^{(u)}$ 近似状态后验概率分布, 并采用样本的加权平均实现状态的最优估计^[29]. 因此, 式(3)的离散估计可以表示为

$$p(\mathbf{v}_{i,k}|\Omega_{i,1:k}) \approx \sum_{u=1}^U \omega_{i,k}^{(u)} \cdot \delta(\mathbf{v}_{i,k} - \chi_{i,k}^{(u)}).$$

其中, $\delta(\cdot)$ 表示狄拉克函数; $\sum_{u=1}^U \omega_{i,k}^{(u)} = 1$, U 表示粒子数, 取经验值 $U = 50$.

根据每个点是否属于尖锐特征, 本文分别取法向和三维高斯随机过程作为状态转移概率

$$p(\mathbf{v}_{i,k}|\mathbf{v}_{i,k-1}) = \mathbf{v}_{i,k-1} + \kappa_i \cdot \phi_{i,k-1} \cdot \hat{\mathbf{n}}_i + (1 - \kappa_i) \cdot \phi_{i,k-1}.$$

其中, $\phi_{i,k} \sim N(0, \varepsilon_{i,k}^2)$ 表示一维高斯函数; $\varepsilon_{i,k}$ 表示噪声带宽; $\phi_{i,k} \sim N(0, \Phi_{i,k})$ 表示三维高斯函数, 具有协方差矩阵 $\Phi_{i,k} = \text{diag}(\varepsilon_{i,k}^2)$.

假定点云隐含曲面是由一系列平面交叠而成的二维流形, 即在局部范围内平面可以看作曲面的一阶近似估计. 本文根据每个点与局部平面的匹配程度构建基于投影误差的观测模型, 如图2所示. 如果观测是相互独立的, 并且观测噪声服从高斯分布, 则每个点的观测似然概率为

$$p(\Omega_{i,k}|\mathbf{v}_{i,k}) = \prod_{j=1}^m \frac{1}{\sqrt{2\pi} \cdot \varepsilon_{i,k}} \exp \left\{ -\frac{1}{2\varepsilon_{i,k}^2} \cdot \left[\frac{\kappa_i}{2} \cdot (e_{j,k}^n)^2 + \left(1 - \frac{\kappa_i}{2}\right) \cdot (e_{j,k}^t)^2 \right] \right\} \quad (5)$$

其中, $e_{j,k}^n = \hat{\mathbf{n}}_i \cdot (\mathbf{v}_{i,k} - \hat{\mathbf{v}}_{j,k-1})$ 表示邻域点投影误差;

$e_{j,k}^t = \hat{\mathbf{n}}_j \cdot (\mathbf{v}_{i,k} - \hat{\mathbf{v}}_{j,k-1})$ 表示特征恢复误差; $\hat{\mathbf{v}}_{j,k-1}$ 表示 $k-1$ 时刻第 j 个邻域点的重构值, 即 k 时刻的邻域点集 $\Omega_{i,k}$. 式(5)中, 右侧第1项用于控制曲面光顺度; 第2项用于控制特征尖锐度.




图2 投影误差似然模型

取状态转移模型为重要性抽样函数, 则 k 时刻点 $\mathbf{v}_i$ 的第 u 个粒子及其权重分别为

$$\chi_{i,k}^{(u)} \sim p(\mathbf{v}_{i,k}|\chi_{i,k-1}^{(u)}),$$

$$\omega_{i,k}^{(u)} \propto \omega_{i,k-1}^{(u)} \cdot p(\Omega_{i,k}|\chi_{i,k-1}^{(u)}).$$

位置状态 $\mathbf{v}_{i,k}$ 的期望即为点 $\mathbf{v}_i$ 在 k 时刻滤波重构后的估值

$$\hat{\mathbf{v}}_{i,k} \approx E(\mathbf{v}_{i,k}) = \sum_{u=1}^U \bar{\omega}_{i,k}^{(u)} \cdot \chi_{i,k}^{(u)}.$$

其中, $\bar{\omega}_{i,k}^{(u)} = \omega_{i,k}^{(u)} / \sum_{u=1}^U \omega_{i,k}^{(u)}$ 表示第 u 个样本粒子的归一化权重.

4.4 几何重采样

为更加有效地模拟状态的真实分布, 基于传统序贯重要性重采样(sequential importance resampling, SIR)^[29]的粒子滤波算法通过复制大权重粒子并删除小权重粒子的方式进行粒子更新; 但是经过几轮迭代后, 只剩少数较大权重粒子, 粒子丧失了多样性, 算法抗干扰能力下降.

为了提高计算效率, 本文根据点云噪声带宽 $\varepsilon_{i,k}$ 自适应地改变重采样范围, 以约束当前点的调整步长; 针对点云不同区域, 分别使用具有法向与球体约束的几何重采样生成新的粒子, 在增加粒子多样性的同时兼顾特征信息, 解决干扰噪声和离群点造成的特征失真问题, 同时保证重构点云

的光顺性. 图 3 所示为粒子重采样过程, 当样本粒子有效数的估值下降到粒子总数一半时进行重采样




图 3 几何重采样示意

(1) 利用式(5)对每个粒子重新分配权重, 并将其作为状态概率分布新的模拟. 根据权重更新下一时刻的噪声带宽

$$\varepsilon_{i,k} = \begin{cases} \sqrt{\frac{1}{t \cdot m} \sum_{i=1}^t \sum_{j=1}^m [\hat{n}_i \cdot (\mathbf{v}_{i,k} - \hat{\mathbf{v}}_{j,k-1})]^2}, & k=0 \\ \max \left\{ \|\mathbf{x}_{i,k-1}^{(u_1)} - \mathbf{x}_{i,k-1}^{(u_2)}\|_{\bar{\omega}_{i,k-1}^{(u)}} \geq 0.2, \right. & k>0 \end{cases}.$$

其中, t 表示非特征点 $\{\mathbf{v}_i | \rho_i \leq \theta\}$ 的个数. 初始带宽 $\varepsilon_{i,0}$ 取非特征点投影误差 $e_{j,0}^n$ 的均方根值. 为了提高计算时效, 重采样后的带宽取权重超过 0.2 的所有粒子间的最大距离作为近似估计.

(2) 在非特征点法线方向 2 倍噪声带宽 $\varepsilon_{i,k-1}$ 范围内, 或特征点处半径为 $\varepsilon_{i,k-1}$ 的球邻域内, 随机生成 U 个粒子

$$\mathbf{x}_{i,k}^{(u)} = \mathbf{x}_{i,k-1}^{(u)} + \kappa_i \cdot \text{rand}(\varepsilon_{i,k-1}) \cdot \hat{\mathbf{n}}_i + (1 - \kappa_i) \cdot \text{rsph}(\varepsilon_{i,k-1}).$$

其中, $\text{rand}(a)$ 产生 $[-a, a]$ 之间的均匀随机数, $\text{rsph}(b)$ 产生半径为 b 球体内的均匀随机数.

点云粒子滤波重构算法的流程如图 4 所示.




图 4 点云粒子滤波重构算法流程图

5 实验及结果分析

将本文算法与多种典型算法对不同点云模型进行重构对比实验. 原始点云模型来自斯坦福大学、AIM@SHAPE 等公开三维扫描数据库; 含噪点云模型是在原始点云模型基础上, 加入沿法向方差为 α 倍 1-环邻域点平均距离的高斯与随机脉冲叠加的混合噪声^[30]. 实验程序采用 C++ 语言编写, 在 Core i5-3.4GHz 笔记本电脑上的 Ubuntu 14.04 LTS 操作系统环境下运行.

5.1 法向估计与尖锐特征辨识

在不同特征阈值参数 θ 下, 尖锐特征辨识与法向估计的结果如图 5 所示. 可以看出: (1) 参数 θ 会影响尖锐特征点识别的灵敏度: θ 较大时, 边缘处只有少数法向变化显著的点被识别为特征点; 反之, 边缘两侧较多冗余点被识别为特征点. (2) 法向权重也会随着 θ 发生改变, 影响法向估计结果. 为了方便观察, 将某个点的局部邻域放大, 并用不同颜色的面元表示各邻域点权重的大小, 此时, 由于权重带宽随着 θ 的增大而变窄, 权重梯度在非

邻域点区域急速下降, 权重呈现各向异性, 使尖锐特征两侧的法向变得分明, 在尖锐特征恢复时提供更加准确的法向约束, 且特征点也更加容易辨识, 如图 5a 所示; 反之, 法向权重趋于各向同性, 尖锐特征两侧的法向也随着权重变化程度的减小而逐渐发生改变, 如图 5b 所示。




图 5 θ 不同时法向估计与尖锐特征识别对比

5.2 重构效果对比

将本文算法和 RIMLS^[9], EAR^[12], CLOP^[13], L_0R ^[16], LR^[18]和 PointProNet^[20]这 6 种典型算法对不同加噪点云模型实验, 结果如图 6~图 8 所示。为了更直观地展示各种算法的重构精度, 在图 6 和图 7 的最后一行给出了误差颜色图。可以看出, 由于 RIMLS 算法^[9]采用局部核回归, 当噪声较强时, 平滑区域难以获得光顺的视觉效果, 尖锐特征也无法得到有效恢复, 如棱边收缩成圆弧倒角; CLOP 算法^[13]由于没有定义连续曲面, 因此处理后点云

的光顺性同样不理想, 其利用非参数估计进行重采样也无法恢复尖锐特征; L_0R 算法^[16]虽然利用特征的稀疏性获得了较好的降噪与尖锐特征恢复效果, 但稀疏优化使得部分曲面特征退化成分段平面, 如 Block 模型的圆孔和 Cater 模型的法兰孔端面; LR 算法^[18]虽然提高了法向估计的精度, 但当噪声较强时, 其使用的双投影优化无法有效地区分尖锐特征和噪声, 整体上难以获得光顺效果, 同时尖锐特征在恢复时也会出现交叉伪影, 如 Block 和 Fandisk 的边缘; EAR 算法^[12]利用法向变化实现各向异性 LOP, 虽然通过重采样可以恢复尖锐特征, 但依然未考虑曲面的连续性, 当噪声较强时无法保证光顺性; 基于数据驱动的 PointProNet 算法^[20]凭借 CNN 可以学习多种特征, 但是需要将三维数据转换为二维局部高度图, 当局部坐标系依赖的法向存在误差时, 点云重构误差会被进一步放大; 本文算法可以有效地恢复不同特征区域法向, 在点云重构时能够更好地保留原有特征, 如 Cater 模型的法兰孔端面。此外, 粒子滤波求解器具有的多假设检验机制能够有效地处理干扰噪声, 并可以减小传统非线性优化或非参数估计的近似误差, 整体视觉效果得到改善。

对原始的 Armadillo 模型进行实验, 进一步验证各种算法对局部特征恢复的效果, 结果如图 8 所示。可以看出, 本文算法能够较好地解决点云重构过程中由于过度平滑和锐化造成的特征畸变问题, 针对不同特征的恢复具有较好的稳定性。

为了量化比较各种算法的性能, 对图 6 和图 7 的结果统计了重构误差与算法时效, 根据重构点云






图 6 7 种算法对加噪 Block 模型($N=20k, \alpha=0.4$)处理后的效果对比

图 7 7 种算法对加噪 Fandisk 模型($N = 27k$, $\alpha = 0.8$)处理后的效果对比图 8 7 种算法对原始 Armadillo 模型($N = 172k$)处理后的局部特征对比

到原始点云网格模型距离的均方根值衡量重构误差^[30], 结果如表 1 所示。可以看出, 7 种算法在重构误差和运行时效上均得到了改善, 重构误差平均减少 46.84%, 算法时效平均提高 33.34%; 与 RIMLS 算法^[9]相比, 本文算法的重构误差平均减少 52.95%, 但是时效性较差; 与 CLOP 算法^[13]相比, 本文算法能够更加准确地估计点的位置, 引入的法向约束也可以更好地恢复特征, 重构误差与时效分别平均改善 65.13%和 85.91%; 与 L_0R 算法^[16]相比, 本文算法的优势是对曲面特征保持得更好, 重构误差平均减少 42.23%, 且无需进行全局组合优化, 时效平均提高 60.18%; 与 LR 算法^[18]相比, 本文算法对边缘恢复更好, 在平面特征为主的模型上精度提升更明显, 重构误差平均减少 56.05%, 而时效平均提高 85.85%; 与 EAR 算法^[12]相比, 本文算法考虑了局部连续性, 因此在平坦区域的光顺性更好, 使得重构误差减少 41.83%, 时效平均提高 69.21%; 与 PointProNet 算法^[20]相比, 本文算法无需大量数据来训练模型, 引入的法向自适应估计可以更加准确地获取隐含面的几何信息, 配合重采样可以高效获得精确计算结果, 重构误差平均减少 22.83%, 时效平

表 1 在 2 个模型上 7 种算法耗时与误差对比

模型	N	α	算法	误差	时间/s
Block	20k	0.4	RIMLS ^[9]	0.0778	5
			CLOP ^[13]	0.0973	85
			L_0R ^[16]	0.0625	35
			LR ^[18]	0.0791	98
			EAR ^[12]	0.0706	45
			PointProNet ^[20]	0.0554	42
			本文	0.0346	13
Fandisk	27k	0.8	RIMLS ^[9]	0.0137	6
			CLOP ^[13]	0.0199	132
			L_0R ^[16]	0.0113	40
			LR ^[18]	0.0154	113
			EAR ^[12]	0.0101	52
			PointProNet ^[20]	0.0074	61
			本文	0.0068	17

注. 粗体表示最优值。

均提高 70.59%。

5.3 消融与鲁棒性实验

依次去除本文算法中的某个步骤后, 对 Cube

模型进行重构消融实验,展示其各步骤对重构结果的影响,结果如图 9 所示.可以看出,图 9b 中,去除法向优化步骤后,尖锐特征处的法向无法根据所属邻域面而分成不同的簇,使得尖锐边缘特征无法得到有效辨识和恢复;同时平坦区域的法向也存在不一致,导致重构后的点云不够光顺;图 9c 中,由于局部曲率随着特征估计的去除而变为常数,因此无法通过权重尺度的调整来更加有效

地辨识噪声和尖锐特征,导致边缘特征恢复存在缺陷;图 9d 中,全部采用法向重采样后平坦区域恢复较好,而尖锐边缘特征区域由于只有单一法向约束,因此出现了交叉伪影;图 9e 中,由于法向包含隐含面的一阶连续性,当平坦区域采用球体重采样时未考虑当前点的法向信息,因此无法保证点云的光顺;图 9f 中,在所有步骤的共同作用下噪声得到抑制,平面和边缘特征得到恢复.




图 9 在加噪 Cube 模型($N=6k$, $\alpha=0.4$)上本文算法消融实验结果

表 2 所示为图 9b~图 9f 中各步骤的重构误差对比.可以看出,本文算法的各个步骤对最终结果都产生正面影响,其中,法向信息是尖锐特征辨识和重采样的基础,因此法向是否得到优化对最终结果的影响较大;特征估计会影响法向优化,对最终结果的影响次之;平坦区域中当前点与其邻域点的法向基本一致,因此 2 种几何重采样对最终结果并不会太大区别,但在尖锐特征处,基于多邻域法向约束的球体重采样优于单一法向约束的法向重采样.

表 2 本文算法各步骤重构误差对比

包含步骤				误差	重构结果
特征估计	法向优化	法向重采样	球体重采样		
√		√	√	1.3453	图 9b
	√	√	√	1.1974	图 9c
√	√	√		0.9517	图 9d
√	√		√	0.8051	图 9e
√	√	√	√	0.6527	图 9f

注:粗体表示最优值.

为了验证本文算法的鲁棒性,对 Bunny 点云模型分别施加尺度为 0.2, 0.4 和 0.6 的噪声,结果如表 3 所示.可以看出,本文算法可以有效地抑制噪声和离群点,具有一定的鲁棒性.此外,从图 6~图 8 中也可以看出,针对具有不同噪声的各类点云模型,本文算法也能获得较为理想的重构结果.

5.4 参数分析

在 Bunny 点云模型上,对本文算法在相同邻域半径 δ 下采用不同特征阈值 θ 重构进行实验,结果如表 4 所示.可以看出:(1) θ 的选取影响了曲面的锐化程度,提升该值将使得较少的点被识别为特征点,点云模型变得更平滑.(2) 随着 r 的减小,点云的滤波结果更加敏感,更多细节特征被保留;反之,点云变得更加光顺,细节特征被丢失.

本文采用随机样本粒子近似各点位置的概率分布估计点位置的最优值,以达到降噪与特征恢复的效果.为了分析粒子数量和重采样算法对本文算法性能的影响,取不同数量粒子分别采用本文和传统 SIR 的重构算法^[29]对图 7 中的 Fandisk 模型进行实验,它们的重构误差和时效对比结果如

表 3 Bunny($N = 34.8k$)模型上本文算法在不同 α 下的重构结果







迭代次数	$\alpha = 0.2$	$\alpha = 0.4$	$\alpha = 0.6$
0			
5			

表 4 特征参数与邻域半径对算法性能的影响







原始点云 ($\alpha = 0.4$)	(θ, δ)				
	(0.05, 6.2)	(0.075, 6.2)	(0.12, 6.2)	(0.12, 5.3)	(0.12, 4.3)
					
					

图 10 所示. 可以看出: (1) 折线图中, 样本数量的增加可以提高重构精度, 但当样本数量超过 50 后精度提高的幅度很小, 而算法运行时间依然随粒子数量成正比增加. (2) 柱状图中, 采用传统 SIR 的算法^[29]需要在完整状态空间中采样, 通过迭代使靠近真值的粒子获得较大权重, 收敛速度较慢; 而本文算法自适应地调整采样带宽加速粒子向真值逼近, 在相同粒子数量情况下, 收敛速度比传统 SIR 算法^[29]平均提高 65.39%, 重构误差平均减少 6.98%.




图 10 粒子数量与重采样算法对 2 种算法性能的影响

6 结 语

本文提出一种具有特征保持的点云概率重构算法. 首先引入具有特征辨识的权重带宽完成邻域的各向异性自适应辨识, 提高特征处法向估计的准确性和特征点辨识度; 然后将点云重构看作贝叶斯框架下点位置后验概率的最大化问题, 并设计了自适应重采样粒子滤波器估计被调整点位置的后验概率分布, 实现点云多假设检验概率重构. 实验结果表明, 本文算法能够在抑制噪声的同时恢复尖锐特征, 有效地提高点云的质量, 为基于点云的三维建模与测量提供一种可以借鉴的预处理算法.

未来, 可以考虑引入点位置的切向调整, 完成点云密度的优化; 进一步, 研究针对动态点云的粒子预测与更新算法, 实现动态点云实时重构.

参考文献(References):

- [1] Han X F, Jin J S, Wang M J, et al. A review of algorithms for

- filtering the 3D point cloud[J]. *Signal Processing: Image Communication*, 2017, 57: 103-112
- [2] Muraki Y, Nishio K, Kanaya T, *et al.* A method of defect extraction for point clouds[OL]. [2023-12-19]. <https://ieeexplore.ieee.org/document/8369693>
- [3] Xu L L, Wang R M, Zhang J Y, *et al.* Survey on sparsity in geometric modeling and processing[J]. *Graphical Models*, 2015, 82: 160-180
- [4] Niu Huiqin, Pan Zhenkuan, Zhao Junli, *et al.* Skull surface reconstruction with Euler's Elastica model from point cloud data[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2022, 34(10): 1515-1523(in Chinese)
(牛慧勤, 潘振宽, 赵俊莉, 等. 颅骨点云曲面重建的 Euler's Elastica 模型[J]. *计算机辅助设计与图形学学报*, 2022, 34(10): 1515-1523)
- [5] Levin D. Mesh-independent surface interpolation[M] //Brunner G, Hamann B, Müller H, *et al.* *Geometric Modeling for Scientific Visualization*. Heidelberg: Springer, 2004: 37-49
- [6] Guennebaud G, Gross M. Algebraic point set surfaces[J]. *ACM Transactions on Graphics*, 2007, 26(3): Article No.23
- [7] Kolluri R. Provably good moving least squares[J]. *ACM Transactions on Algorithms*, 2008, 4(2): Article No.18
- [8] Fleishman S, Cohen-Or D, Silva C T. Robust moving least-squares fitting with sharp features[J]. *ACM Transactions on Graphics*, 2005, 24(3): 544-552
- [9] Öztireli A C, Guennebaud G, Gross M. Feature preserving point set surfaces based on non-linear kernel regression[J]. *Computer Graphics Forum*, 2009, 28(2): 493-501
- [10] Jenke P, Wand M, Bokeloh M, *et al.* Bayesian point cloud reconstruction[J]. *Computer Graphics Forum*, 2006, 25(3): 379-388
- [11] Lipman Y, Cohen-Or D, Levin D, *et al.* Parameterization-free projection for geometry reconstruction[J]. *ACM Transactions on Graphics*, 2007, 26(3): Article No.22
- [12] Huang H, Wu S H, Gong M L, *et al.* Edge-aware point set resampling[J]. *ACM Transactions on Graphics*, 2013, 32(1): Article No.9
- [13] Preiner R, Mattausch O, Arikian M, *et al.* Continuous projection for fast L_1 reconstruction[J]. *ACM Transactions on Graphics*, 2014, 33(4): Article No.47
- [14] Lu X Q, Wu S H, Chen H H, *et al.* GPF: GMM-inspired feature-preserving point set filtering[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2018, 24(8): 2315-2326
- [15] Sun Y J, Schaefer S, Wang W P. Denoising point sets via L_0 minimization[J]. *Computer Aided Geometric Design*, 2015, 35-36: 2-15
- [16] Cheng X, Zeng M, Lin J P, *et al.* Efficient L_0 resampling of point sets[J]. *Computer Aided Geometric Design*, 2019, 75: Article No.101790
- [17] Mattei E, Castrodad A. Point cloud denoising via moving RPCA[J]. *Computer Graphics Forum*, 2017, 36(8): 123-137
- [18] Lu X Q, Schaefer S, Luo J, *et al.* Low rank matrix approximation for 3D geometry filtering[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2022, 28(4): 1835-1847
- [19] Berger M, Tagliasacchi A, Seversky L M, *et al.* A survey of surface reconstruction from point clouds[J]. *Computer Graphics Forum*, 2017, 36(1): 301-329
- [20] Roveri R, Öztireli A C, Pandele I, *et al.* PointProNets: consolidation of point clouds with convolutional neural networks[J]. *Computer Graphics Forum*, 2018, 37(2): 87-99
- [21] Rakotosaona M J, La Barbera V, Guerrero P, *et al.* PointCleanNet: learning to denoise and remove outliers from dense point clouds[J]. *Computer Graphics Forum*, 2020, 39(1): 185-203
- [22] Nakayama K, Fukuta H, Watanabe H. Point cloud denoising and outlier detection with local geometric structure by dynamic graph CNN[C] //Proceedings of the 2023 IEEE 12th Global Conference on Consumer Electronics. Los Alamitos: IEEE Computer Society Press, 2023: 156-159
- [23] Liu Z, Xiao X W, Zhong S S, *et al.* A feature-preserving framework for point cloud denoising[J]. *Computer-Aided Design*, 2020, 127: Article No.102857
- [24] Yadav S K, Reitebuch U, Skrodzki M, *et al.* Constraint-based point set denoising using normal voting tensor and restricted quadratic error metrics[J]. *Computers & Graphics*, 2018, 74: 234-243
- [25] Zhang J, Cao J J, Liu X P, *et al.* Multi-normal estimation via pair consistency voting[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2019, 25(4): 1693-1706
- [26] Mederos B, Velho L, de Figueiredo L H. Robust smoothing of noisy point clouds[C] //Proceedings of the SIAM Conference on Geometric Design and Computing. Brentwood: Nashboro Press, 2003: 1-13
- [27] Wang Y T, Feng H Y, Delorme F É, *et al.* An adaptive normal estimation method for scanned point clouds with sharp features[J]. *Computer-Aided Design*, 2013, 45(11): 1333-1348
- [28] Julier S, Uhlmann J, Durrant-Whyte H F. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. *IEEE Transactions on Automatic Control*, 2000, 45(3): 477-482
- [29] Doucet A, Godsill S, Andrieu C. On sequential Monte Carlo sampling methods for Bayesian filtering[J]. *Statistics and Computing*, 2000, 10(3): 197-208
- [30] Sun X F, Rosin P L, Martin R R, *et al.* Fast and effective feature-preserving mesh denoising[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2007, 13(5): 925-938