

文章编号 1004-924X(2017)12-3169-10

保持特征的散乱点云数据去噪

崔 鑫*, 闫秀天, 李世鹏

(北京宇航系统工程研究所, 北京 100076)

摘要: 为保证在去除点云数据噪声的同时不损失模型的细节特征, 提出了一种基于特征信息的加权模糊 C 均值聚类去噪算法。首先, 构建点云 K-D 树拓扑结构, 根据点的 r 半径球邻域点统计特性去除大尺度离群噪声点。然后, 利用主元分析法估算点云的曲率和法向量, 根据曲率特征标识点云数据的特征区域, 并采用特征加权模糊 C 均值聚类算法对特征区域去噪, 采用加权模糊 C 均值聚类算法对非特征区域去噪。最后, 使用双边滤波器对点云模型进行平滑。对提出的算法进行了验证实验, 结果显示: 去噪后点云模型的最大偏差保持在模型尺寸的 0.15% 以内; 标准偏差保持在模型尺寸的 0.03% 以内。本文算法能够在有效去除不同尺度和强度的噪声的同时不损失点云模型的细节特征, 去噪精度高, 且对不同的噪声模型具有较强的鲁棒性。

关键词: 点云去噪; 加权模糊 C 均值; 曲率权值; 特征保持; 双边滤波

中图分类号: TP391.41 **文献标识码:** A **doi:** 10.3788/OPE.20172512.3169

Feature-preserving scattered point cloud denoising

CUI Xin*, YAN Xiu-tian, LI Shi-peng

(Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China)

* Corresponding author, E-mail: npucuixin@163.com

Abstract: To move the outliers and noisy points away from 3D point cloud data and to maintain the sharp features of the model simultaneously, a feature-based weighted fuzzy C-means point cloud denoising algorithm was proposed. Firstly, the point cloud was organized by K-D tree data structure and the large-scale outliers were removed by the statistics of r radius neighboring points. Then, the principal component analysis method was adopted to estimate the curvature and normal vector of point cloud data and the patches with distinguished features were identified according to the curvature feature weight. Pursuant to different feature regions, the feature-preserving weighted fuzzy C-means clustering algorithm was adopted to denoise for the patch with rich feature information and the fuzzy C-means clustering algorithm was adapted to denoise for the patch with less feature information, respectively. Finally, a bilateral filter was used to smooth the data set. The algorithm was verified and the experimental results show that the max denoising error is limited to 0.15% of the model size and the min denoising error is limited to 0.03% of the model size. In conclusion, this approach moves efficiently and precisely the noise with different scales and intensities in point cloud, meanwhile performing a feature-preserving nature. Moreover, it is robust enough to different noise models.

收稿日期: 2017-06-23; 修订日期: 2017-08-15.

基金项目: 国家国际科技合作专项资金资助项目 (No. 2013DFA51360)

Key words: point clouds de-noising; weighted fuzzy c-means; curvature weight; feature preserving; bilateral filter

1 引言

随着三维激光扫描技术和计算机技术的发展,三维点云数据在逆向工程、精密制造和虚拟现实等领域得到了广泛地应用^[1,2],因此点云数据高效率、高精度的处理方法成为各个应用领域的热点研究内容。但由于受测量设备、外部环境和被测物体表面特性等诸多因素影响,测得的点云数据不可避免地出现噪声,直接影响后期三维建模的精度和效率,因此在点云数据的预处理阶段需要进行去噪。一种优良的点云数据去噪算法应当具有以下特点:在有效去除噪声的同时能够保持模型的尖锐几何特征,减少模型的收缩和扭曲变形;同时,算法复杂度低,且对不同的噪声模型具有较高的鲁棒性。

近年来,国内外学者针对散乱点云数据去噪方法进行了深入研究,提出了多种点云去噪算法。Jones 等^[3]提出了一种无需迭代的各向异性的去噪算法,该方法通过邻域点预测网格顶点的位置并对顶点进行调整;Fleishman 等^[4]首先将应用于图像双边滤波的方法扩展到三维网格模型的去噪上,将顶点的位置沿顶点的法线方向进行调整,从而达到去噪目的。但两种方法在不同特征区域不能自适应调整,存在大尺度噪声时会产生过光顺问题;王丽辉^[5]将模糊 C 均值聚类算法(Fuzzy C-means,FCM)结合双边滤波方法应用于点云数据去噪,分步处理不同尺度的噪声,并取得了较好的效果,但其没有区分特征区域与平坦区域;袁小翠^[6]等采用 K 均值聚类方法对三维数据进行平滑,对点云模型的特征区域与平坦区域进行识别,从而对点云数据分类处理;Wang^[7]等将改进的移动最小二乘法去噪扩展到三维空间,利用采样点之间的相关系数计算自适应权重向量,将采样点移动到对应的局部曲面,从而去除噪声,该方法具有较好的鲁棒性;在对基于特征的去噪方法^[8-11]的研究中,多位学者提出要首先对特征区域与非特征区域进行分类识别,然后分别利用不同的滤波方法对点云数据进行去噪,但其时间成本一般较高;Haque 等^[12]利用点云数据的法向量以及数

据点之间的距离双重标准检测孤立点,然后对点的法向量利用双边权重进行平滑,对数据点根据法向量进行重定位,从而保持点云数据模型的特征;Jun^[13]提出首先利用椭球体准则去除大尺度噪声,然后对点云模型的小尺度噪声进行均值滤波的两步去噪方法,取得了较好的效果;在对基于图像^[14]的去噪方法研究中,Rosman 等^[15]将图像中的邻域匹配方法应用于三维空间,在邻域中通过 Laplace-Beltrami 算子用鲁棒的方法生成一个平滑曲面来去除高频噪声,但同时也降低了点云数据的表示精度;Zaman 等^[16]提出了一种基于密度的点云数据去噪,首先采用粒子群优化算法对点云数据的密度进行估计,然后利用 K 均值聚类算法去除噪声点,双边滤波进行平滑。

针对以上问题,本文提出一种基于特征信息的加权模糊 C 均值点云去噪算法,本算法根据点云模型的特征信息引入了特征保持权重因子,从而在聚类过程中增强了特征明显处的点对聚类结果的影响。同时本文结合双边滤波算法,对点云数据的小尺度噪声进行光顺。相较于以往的去噪算法,该算法能够在去除复杂噪声的同时保持点云模型的尖锐特征。

2 算法描述

基于特征信息的加权模糊 C 均值聚类点云去噪算法主要分为以下几个步骤:首先,构建点云模型的 K-D 树拓扑结构,由点的 r 半径包围球内邻域点的数目去除大尺度离群噪声点。然后,根据点云数据模型的曲率特征对点云数据中的特征点进行识别分类,对含特征信息丰富的区域点,采用特征保持的加权模糊 C 均值聚类方法去噪,对特征不明显的平坦区域点采用模糊 C 均值聚类算法去噪。最后,对去除大尺度噪声后的点云数据进行双边滤波光顺。具体的算法流程如图 1 所示。

2.1 点云法向量与曲率的计算

经过三维扫描仪获得的点云数据为散乱点云,一般只含有三维坐标信息。而点云数据的法向量和曲率能够反映点云数据的特征信息,对后

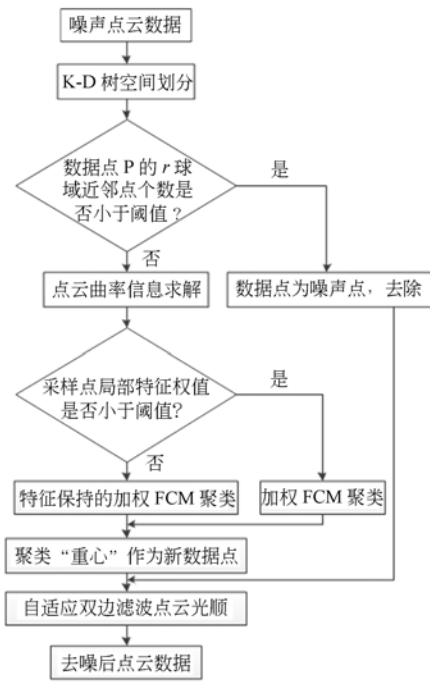


图 1 算法流程图

Fig. 1 Flow chart of proposed algorithm

续点云数据预处理、点云特征提取及点云曲面重建具有非常重要的作用。

由于散乱点云中点与点之间没有明确的拓扑关系,在对点云数据的法向量和曲率进行估算时,首先需要建立点与点之间的拓扑结构关系,本文采用 K-D 树数据结构建立点云之间的拓扑关系,以点的 k 邻域为基础采用主成分分析法(PCA)计算点云数据的法向量及曲率。

设点 p_i 的 k 邻域点集为 $N_k(p_i)$ 构造关于点 p_i 的 3×3 协方差矩阵如式(1)所示:

$$C = \begin{bmatrix} p_1 - \bar{p} \\ \dots \\ p_k - \bar{p} \end{bmatrix}^T \begin{bmatrix} p_1 - \bar{p} \\ \dots \\ p_k - \bar{p} \end{bmatrix}, \bar{p} = \frac{1}{k} \sum_{p_j \in N_k(p_i)} p_j, \quad (1)$$

其中: \bar{p} 为数据点 p_i 及其 k 邻域所构成集合的质心,矩阵 C 表示了点集 $N_k(p_i)$ 的点的分布情况,即邻域点与质心点 \bar{p} 的偏离程度。矩阵 C 为对称半正定矩阵,所以有 3 个非负实数特征值,设为 $\lambda_0, \lambda_1, \lambda_2$, 且 $\lambda_0 \leq \lambda_1 \leq \lambda_2$, 其对应的特征向量分别为 v_0, v_1, v_2 。最小特征值 λ_0 对应的特征向量 v_0 即可近似为点 p_i 的法向量,同时 p_i 点的平均曲率 H_i 也可以被近似估算为:

$$H_i = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2}. \quad (2)$$

然后,将上述计算所得的点云法矢的方向调

整一致。

2.2 点云曲率特征计算

本文采用文献[17]中基于平均曲率的方法计算特征权值,对于 $\forall p_i \in P$, 其 k 邻域点集为 $q_i \in Q (i=1, 2, \dots, k)$, 已知点 p_i 处的平均曲率为 H_i , 则定义数据点 p_i 在 k 邻域下的局部权值计算公式如式(3)所示:

$$s_i = \sqrt{\frac{1}{k} \sum_i^k (|H_{q_i} - \bar{H}|)^2 + \sqrt{(H_i - \bar{H})^2}}, \quad (3)$$

$$\bar{H} = \frac{1}{n} \sum_{i=1}^n H_i, \quad (4)$$

其中: H_{q_i} 为 k 邻域点集内点的平均曲率,对于 $\forall p_i \in P$, 若该点处的局部特征权值大于给定的阈值,即 $s_i > s_{th}$, 则认为该点为 k 邻域下的特征信息丰富的点,否则,若该点处的局部特征权值小于给定的阈值,即 $s_i < s_{th}$, 则认为该点为平坦区域点。对于不同区域点,采用相应的模糊 C 均值聚类算法进行去噪。

2.3 特征加权模糊 C 均值聚类

模糊 C 均值聚类(FCM),是用隶属度确定每个数据点属于某个类别的程度,由 Dunn 在 1973 年提出并由 Bezdek 加以推广的一种聚类方法。

FCM 把包含 n 个 l 维向量 $p_i (p_{i1}, \dots, p_{il})$ 的集合 $P = \{p_1, p_2, \dots, p_n\}$ 分为 m 组,每组对应一个聚类中心 $O = \{o_1, o_2, \dots, o_m\}$, 计算每个聚类组的聚类中心 $o_j, (j=1, \dots, m)$, 使得目标函数 J 达到最小,其中 J 的表达式如式(5)所示:

$$J(U, O) = \sum_{j=1}^m \sum_{i=1}^n u_{ij}^t d_{ij}^2 (p_i - o_j), s \in [0, 1), \quad (5)$$

$$\sum_{j=1}^m u_{ij} = 1, \forall i = 1, \dots, n, \quad (6)$$

$$d_{ij}^2 (p_i - o_j) = \left\| \frac{p_i - o_j}{\omega_{ij}} \right\|_2^2 = \frac{1}{\omega_{ij}^2} \sum_{k=1}^l |p_{ik} - o_{jk}|^2, \quad (7)$$

$$\omega_{ij} = \mu_{ij} / \sum_{i=1}^n \mu_{ij}, \quad (8)$$

其中: U 为隶属度矩阵, U 中的每一元素 $u_{ij} \in [0, 1]$ 表示每个给定向量属于各个聚类组的程度,且对于任意向量 x_j , 其隶属于各个聚类的隶属度满足约束式(6); t 为模糊控制度参数; $d_{ij}^2 (p_i - o_j)$ 为改进的向量 p_i 与聚类中心 o_j 的欧氏距离,表达

式如式(8)所示。

改进的模糊聚类方法中模糊权重系数使得距离远的向量对聚类中心的影响变小,距离近的向量对聚类中心的影响变大。因此可以有效地扩大离群向量的特征,从而使得聚类算法更加精确。

本文在此基础上,针对三维空间散乱点云数据提出了一种特征加权模糊 C 均值聚类算法,对于每一个数据点,利用数据点的空间位置信息及微分几何信息分别进行聚类,得到两种聚类中心,然后对两种聚类中心再次进行加权得到该数据点应该移动到的位置。对于任一点 $p_i(p_{ix}, p_{iy}, p_{iz})$ 所对应的平均曲率为 H_i ,计算每一个数据点的特征保持权重因子,如式(9)所示:

$$\omega_{H_i} = \frac{H_i}{\sum_{j=1}^n H_j}, 1 \leq i \leq n, \quad (9)$$

用 ω_{H_i} 表示数据点 p_i 的曲率对聚类的影响程度。数据点 p_i 的曲率值越小,说明数据点位置处越平坦,其包含的特征也就越小,从而其特征保持权重因子 ω_{H_i} 也越小,对聚类的影响程度也就越小。而模型的特征部位数据点的特征保持权重较大,对聚类的影响程度也就越大,从而在聚类过程中保持点云数据的尖锐特征。

对于每一个数据点,定义其密度计算公式如式(10)所示:

$$\rho_i = \sum_{j=1, j \neq i}^n \frac{1}{\|p_i - p_j\|_2}, \quad (10)$$

$$\|p_i - p_j\|_2 = \sqrt{(p_{ix} - p_{jx})^2 + (p_{iy} - p_{jy})^2 + (p_{iz} - p_{jz})^2}. \quad (11)$$

两个数据点之间的欧式距离如式(11)所示,当数据点周围数据分布密度较大时,数据点之间的距离也比较近,从而 ρ_i 也比较大,因此建立密度影响权重因子:

$$\omega_{\rho_i} = \frac{\rho_i}{\sum_{j=1}^n \rho_j}, 1 \leq i \leq n, \quad (12)$$

用 ω_{ρ_i} 表示数据点 p_i 的密度对聚类的影响程度,数据点周围密度越小,它与周围 n 个数据点的距离也就越大,权重 ω_{ρ_i} 越小,该数据点对聚类的影响越小。而模型的真实数据点周围数据点密度大对分类的影响也就越大。

模糊 C 均值聚类的权重因子取为特征保持权重因子 ω_{H_i} 与密度权重因子 ω_{ρ_i} 的加权值,可以

得到目标函数如式(13)所示:

$$J(\mathbf{U}, \mathbf{C}, \omega) = \sum_{j=1}^m \sum_{i=1}^n (\alpha_{\rho} \omega_{\rho_i} + \alpha_{H_i} \omega_{H_i}) u_{ij}^s d_{ij}^2 (p_i - o_j), \quad (13)$$

其中, $s \in [0, 1)$, $\alpha_{\rho} + \alpha_{H_i} = 1$ 。 α_{H_i} 为特征保持系数,其值越大,曲率大的数据点对聚类效果的影响所占比重越大,特征信息保持能力越强; α_{ρ} 为密度影响系数,其值越大则密度(空间距离)对聚类效果的影响所占比重越大,去除噪声数据的效果越好。其中,特征保持系数 α_{H_i} 采用极差化线性求解,利用局部特征权重。当局部特征越大时,特征保持系数也应越大,从而提高局部尖锐特征处点对聚类中心的影响,计算公式如式(14)所示:

$$\alpha_{H_i} = \frac{s_i - s_{\min}}{s_{\max} - s_{\min}}, \quad (14)$$

其中: s_{\max} 为局部特征权值的最大值; s_{\min} 为局部特征权值的最小值; s_i 为数据点处的局部特征权重。采用该种计算方法计算特征保持系数能够较好的保留相对局部特征,避免了使用全局特征权值的极值时,特征不均匀造成的对局部特征的湮没。

对于任一数据点 p_i 的 r 包围球内的点进行聚类,得到其对于每个聚类中心的隶属度 u_{ij} ,将数据点 p_i 移向聚类“重心” \bar{o} , \bar{o} 取为每个聚类中心对于隶属度的加权平均,如式(15)所示:

$$\bar{o} = \sum_{j=1}^m u_{ij} o_j. \quad (15)$$

图 2 解释了特征加权模糊 C 均值聚类的原理。




图 2 特征加权模糊 C 均值聚类

Fig. 2 Illustration figure of clustering process

对于图 2 中点 1 位置包围球内近邻点个数大于阈值,将 1 移向聚类中心,噪声得到了平滑。点 2 位于点云数据中特征信息丰富处,若采用原模糊 C 均值聚类方法进行聚类,则聚类中心会移向

离邻域点距离之和最近的地方,如图 2 中空心三角形处,从而导致尖锐特征被光顺。在加入特征保持权值因子后,由于点 2 处曲率较大,因此特征保持权值因子较大,在聚类过程中,点 2 与聚类中心的距离对指标函数的影响也就越大,聚类中心会移向点 2 处,因此点云数据的特征部分得到了有效保留。点 3 处,包围球内近邻点的个数小于阈值,判定为离群噪声点,予以去除。点 4 位于平坦区域,在密度分布均匀的平坦区域采用模糊 C 均值聚类算法,其聚类中心就是数据点本身,不发生变化。

$$\lambda = \frac{\sum_{p_j \in N_k(p_i)} W_C(\|p_j - p_i\|) W_S(\|\langle n_j, n_i \rangle\| - 1) \langle n_i, p_j - p_i \rangle}{\sum_{p_j \in N_k(p_i)} W_C(\|p_j - p_i\|) W_S(\|\langle n_j, n_i \rangle\| - 1)}, \quad (17)$$

其中: $\langle \cdot, \cdot \rangle$ 表示向量内积, n_j, n_i 为点的法向量,可由 PCA 方法求出; W_C, W_S 分别表示双边滤波函数的空间域和频率域权重函数,它们分别控制着双边滤波的平滑程度和特征保持程度。其形式是以 σ_c, σ_s 为标准差的高斯核函数,具体形式如式(18)所示:

$$W_C(x) = e^{-\frac{x^2}{2\sigma_c^2}}, W_S(y) = e^{-\frac{y^2}{2\sigma_s^2}}, \quad (18)$$

其中: σ_c 表示数据点 p_i 到邻域点的距离对点 p_i 的影响因子, σ_c 越大对点云的光顺效果越好,但其特征保持能力越差。表示点 p_i 与其近邻点的法向偏差对点 p_i 的影响因子, σ_s 越大对特征的保持效果越好。通常情况下, σ_c 取点的邻域半径, σ_s 取为邻域点的标准偏差。

双边滤波算法的具体步骤如下:

- (1) 计算每个数据点 p_i 的 k 邻域点 $N_k(p_i)$;
- (2) 对 p_i 的每个临近点求取 W_C 的参数 $\|p_j - p_i\|$ 和 W_S 的参数 $\|\langle n_j, n_i \rangle\| - 1$,以及参数 $\langle n_i, p_j - p_i \rangle$;
- (3) 由式(18)计算高斯核函数 $W_C(x)$ 和 $W_S(y)$;
- (4) 根据式(17)计算出双边滤波因子 λ ;
- (5) 根据式(16)计算滤波后的数据点;
- (6) 依次计算所有数据点完成点云滤波光顺。

3 实验结果与分析

为验证本文算法的有效性,首先将本文算法

2.4 双边滤波光顺

双边滤波算法^[18]主要用于对点云数据的小尺度起伏噪声进行平滑光顺。双边滤波应用于三维点云数据去噪,既有效地对空间三维模型表面进行降噪,又可以保持点云数据中的几何特征信息,避免三维点云数据被过渡光滑。在点云模型中设点 p_i 的 k 邻域点集及单位法向量分别为 $N_k(p_i)$ 与 n_i 双边滤波可以定义为式(16):

$$\hat{p}_i = p_i + \lambda n_i, \quad (16)$$

其中: \hat{p}_i 为双边滤波后更新的点, λ 为双边滤波因子,其计算公式如式(17)所示:

与现有算法的去噪效果进行对比,然后对不同信噪比的模型进行去噪实验并分析实验结果。实验环境所用硬件配置为 Intel i7-4790/3.60GHz/4GB。

3.1 不同算法去噪效果对比

本节首先选取 Stanford Bunny 模型进行去噪实验,原始模型共包含数据点 35 947 个,如图 3(a)所示。图 3(b)为原始模型的三角化模型。图 3(c)标识出了模型的主要特征区域,从而更好地验证算法的特征保持性能。在点云模型中随机选取一定数量的数据点,将其沿法向量方向随机偏离一定的距离,偏离的幅值与模型尺度有关,并且服从高斯分布,噪声模型如式(19)所示:

$$p'_i = p_i + \epsilon n_{p_i}, \quad (19)$$

其中: p_i 为原数据点, p'_i 为添加噪声后的数据点, n_{p_i} 为点的法向量, $\epsilon \sim N(\mu, \sigma^2)$ 为随机噪声幅值因子,期望值 μ 与模型尺度相关, i 为随机整数。图 3(d)为添加信噪比为 5 dB 的高斯白噪声数据后的点云模型,图 3(e)为加入噪声数据后点云的重建模型。为直观显示加入噪声后的效果及去噪结果,后续实验中给出的均为重建模型。

分别采用 Laplace 去噪算法、模糊 C 均值去噪算法、双边滤波算法、基于核密度的去噪算法^[16]和本文提出算法进行去噪。将去噪后的点云数据进行三角化以便于显示,实验结果如图 4 所示,图 4(a)~4(e)依次为 5 种算法的去噪结果。对比图 4(a)~4(c)与图 4(e)可以看出本文算法去噪后,模型表面的凸起与凹陷等特征信息

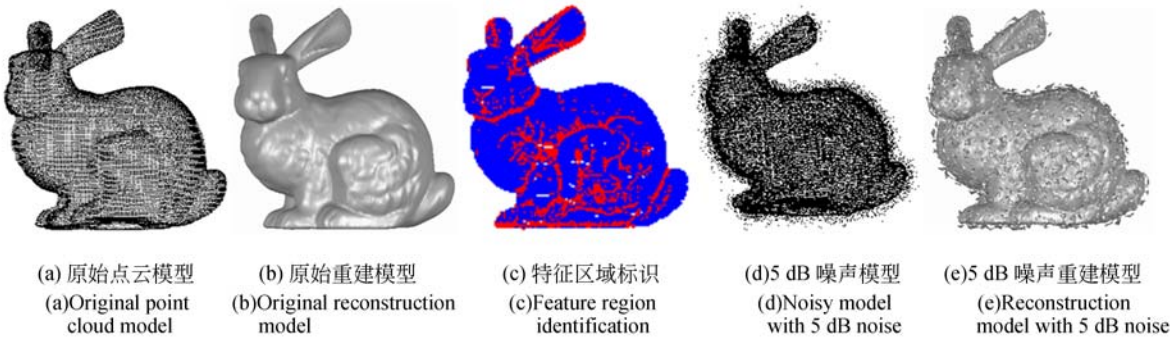


图 3 Bunny 原始模型与噪声模型
Fig. 3 Original model and noisy model of Bunny

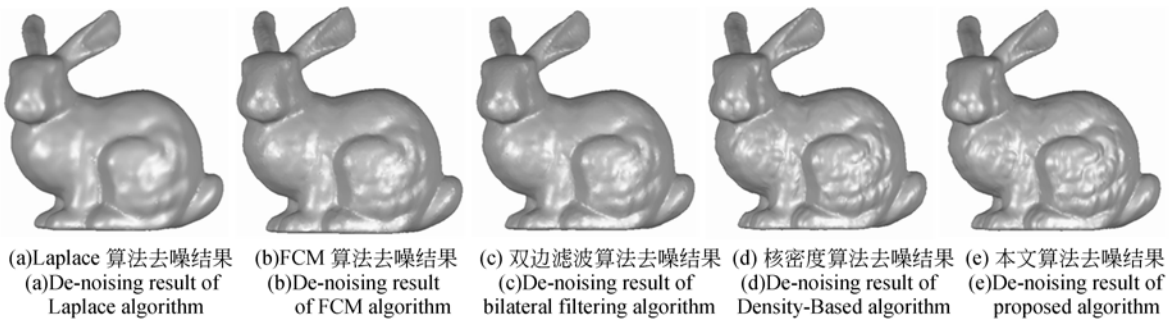


图 4 不同去噪算法去噪结果
Fig. 4 De-noising results of different method

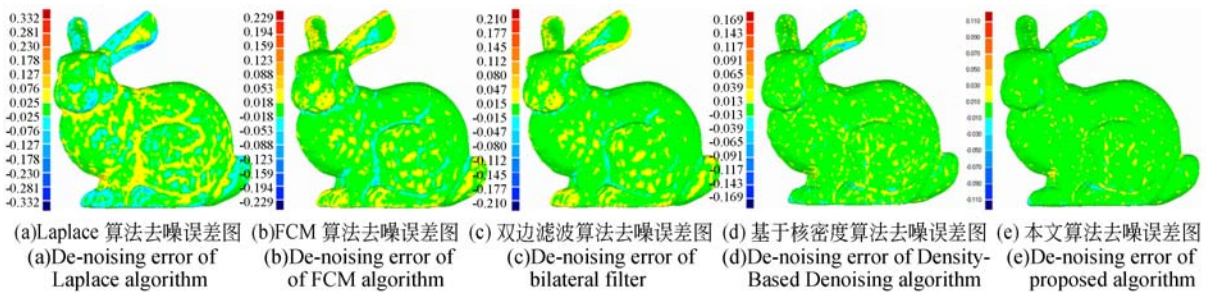


图 5 不同去噪算法误差图
Fig. 5 De-noising error of different method

被保留了下来。前 4 种去噪方法都一定程度地损失了模型的细节特征,图 4(a)去噪结果产生了过光滑现象模型的高频特征被光滑除去。对比可知本文算法表现出优良的保持模型特征的特性。利用最近点迭代算法(ICP)寻找去噪后的模型与原模型之间的对应点,将对应点之间的欧式距离作为误差,利用 Geomagic 软件对 2 个模型执行 3D 比较,得到 5 种去噪算法的误差图如图 5 所示,不同去噪算法误差及运行时间对比如表 1 所示。算法平均误差约为模型尺寸的 0.018%。最大误差

表 1 不同去噪方法误差表

Tab. 1 De-noising error of different methods

去噪算法	平均误差/mm	最大误差/mm	运行时间/s
Laplace 算法	0.057 4	0.331 8	10.588
模糊 C 均值聚类	0.033 9	0.229 3	5.039
双边滤波	0.036 7	0.209 6	4.467
基于核密度去噪	0.307 7	0.168 9	7.892
本文算法	0.021 9	0.110 4	6.683

约为模型尺寸的 0.114%。同时本文算法整体复杂度为 $O(N \log N)$,其中 N 为点云中数据点个数。

算法复杂度与以上 4 种算法基本相当,因迭代次数不同算法运行时间略有差异。因此,本文算法能够

在较好保持模型特征、减小模型的去噪误差的同时使算法的运行效率也能够满足实际工程应用。

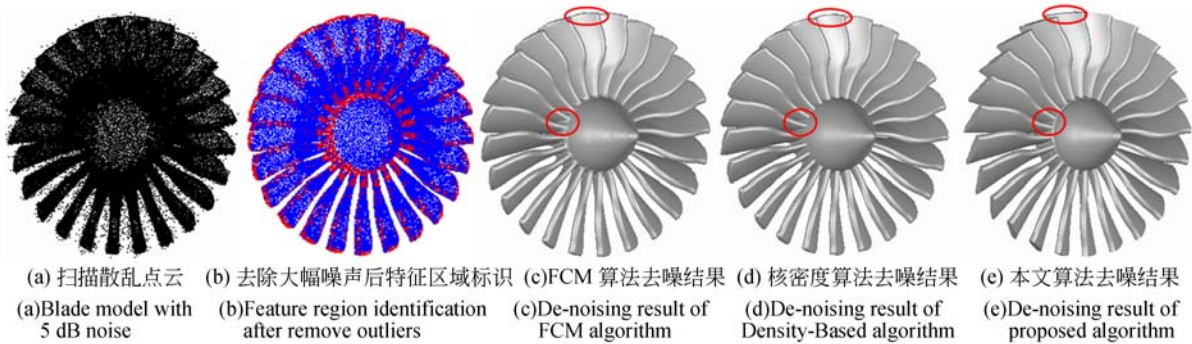


图 6 涡扇点云不同去噪算法去噪结果

Fig. 6 De-noising results of different method performed on turbofan

为进一步验证算法的有效性,文章对涡扇扫描点云进行去噪实验。涡扇点云模型共包含数据点 112 710 个,点云如图 4(a)所示,点云模型中含有少量噪声,尤其在边缘处噪声出现积聚。图 4 (b)为涡扇模型去除大尺度噪声后点云特征识别的效果图,由图可以看出点云的特征区域主要集中在风扇边缘以及扇轴焊接处,此处是模型尖锐特征的主要聚集处。分别采用模糊 C 均值去噪

算法、基于核密度的去噪算法^[16]和本文提出算法进行去噪,去噪结果如图 4(c)~4(e)所示(彩图见期刊电子版),如图红色圈中部分,采用前两种算法去噪后,涡扇的边缘部分及扇轴焊接处的特征被平滑,从而丢失了原模型特征。3 种算法的运行时间依次分别为:22.457 s、26.399 s、24.637 s,因此,采用本文算法进行去噪后能够在较好地保持模型特征的同时保证算法运行的效率。




图 7 不同强度噪声下 blade 模型

Fig. 7 Bunny model with different signal-to-noise ratio

3.2 不同噪声强度去噪效果比较

为测试本文算法的性能,选取 Stanford Blade 模型进行实验,原始模型共包含数据点 234 622 个,对点云模型分别添加信噪比为 5 dB、10 dB、15 dB、20 dB 的高斯白噪声,不同强度噪声下的

三角化模型及特征标识图如图 7 所示。采用本文算法对不同噪声强度下的模型进行去噪,表 2 给出了不同强度噪声下的去噪误差结果数据及运行时间。误差结果图如图 8 所示,根据表 2 以及图 8 可以看出随着噪声强度的增加,去噪误差也逐

渐增加,但始终保持在较小的水平之内,即使在信噪比较小的情况下,模型的尖锐特征也被完好地保存下来,同时,算法运行效率基本满足应用需求。模型去噪后整体偏差很小,平均误差约为模型尺寸的 0.013%。最大误差约为模型尺寸的 0.099%。因此本文算法对不同强度噪声下的模型去噪具有较强的鲁棒性。

表 2 不同强度噪声下去噪结果

Tab. 2 De-noising error of blade model with different signal-to-noise ratio

噪声强度/dB	平均误差/mm	最大误差/mm	运行时间/s
5	0.179 9	1.157 3	43.255
10	0.143 5	0.915 7	44.466
15	0.136 1	0.886 3	41.772
20	0.109 3	0.725 5	45.622

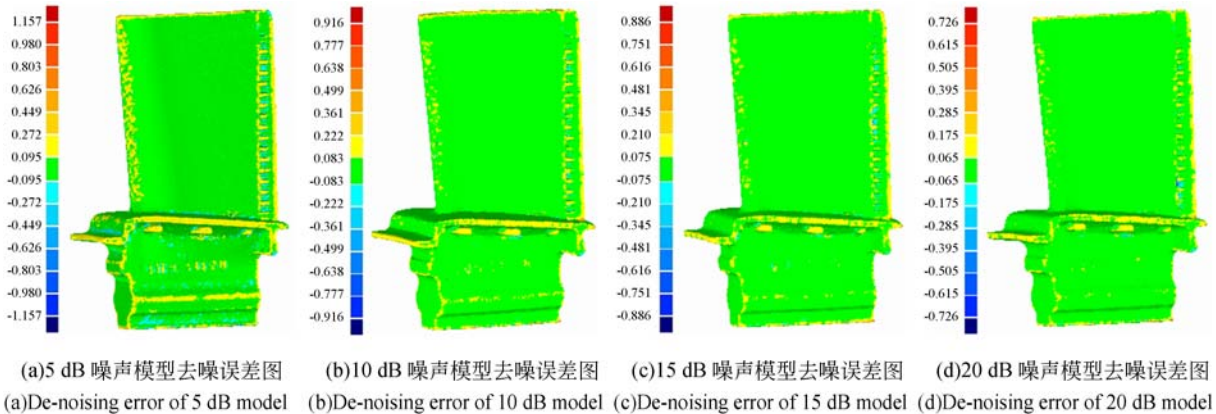


图 8 不同强度噪声去噪模型误差图

Fig. 8 De-noising error of different signal-to-noise ratio

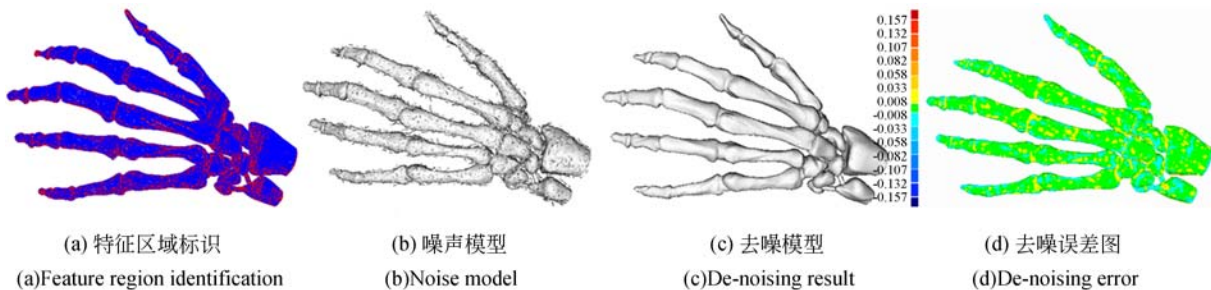


图 9 Hand 模型去噪结果

Fig. 9 De-noising algorithm performed on hand model

3.3 复杂特征模型的去噪结果

为进一步验证本文算法对于细节特征的保持特性,本文同时选取了细节特征复杂的 hand 模型进行去噪实验。hand 模型共包含 82 845 个数据点。对 hand 加入信噪比为 10 dB 的高斯白噪声后的三角化模型如图 9(b)所示,利用本文算法对其进行去噪处理,得到去噪后的三角化模型如图 9(c)所示。图 9(d)为去噪后的误差图,去噪后数据点个数为 75 736 个,平均误差为 0.028 4 mm,约为模型尺寸的 0.024%,最大误差为 0.157 2 mm,约为模型尺寸的 0.144%,算法运行时间为

11.933 s。由图 9(c)、图 9(d)可以看出去噪后的模型较好地保持了模型的细节特征,避免了过光滑现象,同时去噪后模型的整体误差保持在较小的水平,仅在指尖关节以及手腕结合部位等特征复杂的地方存在小的偏差。

4 结 论

针对三维散乱点云数据去噪过程中,点云数据的复杂噪声难以去除以及点云模型的特征易被过光滑的问题,本文提出了一种基于特征信息的

加权模糊 C 均值点云去噪算法。在传统模糊 C 均值聚类算法中引入了特征保持权值因子,将点云模型中特征明显的部分保留下来。同时结合 r 半径邻域点统计特性,以及双边滤波算法对不同尺度噪声进行去除和平滑。通过对 Stanford bunny 噪声模型采用不同的去噪算法进行实验结果比对,同时应用本文算法对加入不同强度的噪声下的 blade 模型进行去噪实验以及对误差结果

进行分析验证。最后对具有复杂细节特征的 hand 模型进行去噪实验。实验结果表明,利用本文算法去噪后,点云模型的最大偏差保持在模型尺寸的 0.15% 以内;标准偏差保持在模型尺寸的 0.03% 以内,同时,本文算法能够在去除复杂噪声的同时,保持模型的细节特征不被光顺,针对不同噪声强度以及具有复杂特征的噪声模型,本文算法都表现出优良特性,具有较高的鲁棒性。

参考文献:

- [1] MOORFIELD B, HAEUSLER R, KLETTE R. Bilateral filtering of 3D point clouds for refined 3D roadside reconstructions [C]. *International Conference on Computer Analysis of Images and Patterns*, Springer, 2015: 394-402.
- [2] 张雨禾, 耿国华, 魏萧然. 散乱点云谷脊特征提取 [J]. *光学精密工程*, 2015, 23(1): 310-318.
ZHANG Y H, GENG G H, WEI X R. Valley-ridge feature extraction from point clouds [J]. *Opt. Precision Eng.*, 2015, 23(1): 310-318. (in Chinese)
- [3] JONES T R, DURAND F, DESBURN M. Non-iterative, feature-preserving mesh smoothing [J]. *ACM Transactions on Graphics*, 2003, 22(3): 943-949.
- [4] FLEISHMAN S, DRORI I, COHEN-OR D. Bilateral mesh denoising [J]. *ACM Transactions on Graphics*, 2003, 22(3): 950-953.
- [5] 王丽辉. 三维点云数据处理的技术研究 [D]. 北京: 北京交通大学, 2011.
WANG L H. *Study on data processing technology of 3D cloud points* [D]. Beijing: Beijing Jiaotong University, 2011. (in Chinese)
- [6] 袁小翠, 吴禄慎, 陈华伟. 特征保持点云数据精简 [J]. *光学精密工程*, 2015, 23(9): 2666-2676.
YUAN X C, WU L SH, CHEN H W. Feature preserving point cloud simplification [J]. *Opt. Precision Eng.*, 2015, 23(9): 2666-2676. (in Chinese)
- [7] WANG X Z, LI Z K, MAI Y Q, et al.. Robust denoising of unorganized point clouds [C]. *Proceedings of the 2011 International Conference on Intelligent Computing and Integrated Systems*, IEEE, 2013: 1-3.
- [8] GU X Y, LIU Y S, WU Q. A filtering algorithm for scattered point cloud based on curvature features classification [J]. *Journal of Information and Computational Science*, 2015, 12(2): 525-532.
- [9] 吴禄慎, 史皓良, 陈华伟. 基于特征信息分类的三维点数据去噪 [J]. *光学精密工程*, 2016, 24(6): 1465-1473.
WU L SH, SHI H L, CHEN H W. Denoising of three-dimensional point data based on classification of feature information [J]. *Opt. Precision Eng.*, 2016, 24(6): 1465-1473.
- [10] 曹爽, 岳建平, 马文. 基于特征选择的双边滤波点云去噪算法 [J]. *东南大学学报(自然科学版)*, 2013, 43(S2): 351-354.
CAO SH, YUE J P, MA W. Bilateral filtering denoise algorithm for point cloud based on feature selection [J]. *Journal of Southeast University (Natural Science Edition)*, 2013, 43(S2): 351-354. (in Chinese)
- [11] LIU C, YAN D, ZHAO H W. 3D point cloud denoising and normal estimation for 3D surface reconstruction [C]. *Proceedings of the 2015 IEEE Conference on Robotics and Biomimetics*, IEEE, 2015: 820-825.
- [12] HAQUE S M, GOVINDU V M. Robust feature-preserving denoising of 3D point clouds [C]. *Proceedings of the 2016 4th International Conference on 3D Vision*, IEEE, 2016: 83-91.
- [13] JUN S. Two-stage point-sampled model denoising by robust ellipsoid criterion and mean shift [C]. *Proceedings of the 2013 3rd International Conference on Intelligent System Design and Engineering Applications*. IEEE, 2013: 1581-1584.
- [14] SCHOENENBERGER Y, PARATTE J, VANDERGHEYNST P. Graph-based denoising for time-varying point clouds [C]. *3DTV - Conference: The True Vision-Capture, Transmission and Display of 3D Video*, IEEE, 2015: 1-4.
- [15] ROSMAN G, DUBROVINA A, KIMMEL R.

- Patch-collaborative spectral surface denoising[J]. *Computer Graphics Forum*, 2013, 32(8): 1-12.
- [16] ZAMAN F, WONG Y P, NG B Y. Density-based denoising of point cloud[C]. *Proceedings of the 9th International Conference on Robotic, Vision, Signal Processing and Power Applications, Springer*, 2017: 287-295.
- [17] 程效军, 贾东峰, 程小龙. 海量点云数据处理理论与技术[M]. 上海: 同济大学出版社, 2014: 5.
- CHENG X J, JIA D F, CHENG X L. *Theory and Technology of Mass Point Cloud Data Pretreatment* [M]. Shanghai: Tongji University Press, 2014: 5. (in Chinese)
- [18] CHAUDHURY K N. Acceleration of the shifttable O(1) algorithm for bilateral filtering and nonlocal means[J]. *IEEE Transactions on Image Processing*, 2013, 22(4): 1291-1300.

作者简介:



崔 鑫(1993—),男,山东菏泽人,硕士,助理工程师,2015年于西北工业大学获得学士学位,主要从事三维重建与逆向工程方面的研究。E-mail: npucuixin@163.com

导师简介:



闫秀天(1964—),男,陕西西安人,博士,教授,博士生导师,获英国拉夫堡技术大学博士学位,国家“千人计划”创新人才,国际机电一体化论坛学会副主席,现为英国 Strathclyde 大学工学院副院长,中国航天科技集团公司北京宇航系统工程研究所特聘教授。主要从事生物骨快速成型、微机电设计与仿真方面的研究。E-mail: xt8_yan@163.com