

激光点云的混合流形谱聚类自适应分割方法

王 帅¹, 孙华燕², 郭惠超², 都 琳¹

¹中国人民解放军装备学院研究生管理大队, 北京 101416;

²中国人民解放军装备学院光电装备系, 北京 101416

摘要 将激光点云视为分布于三维欧氏空间的线性与非线性混合流形, 提出一种基于混合流形谱聚类的自适应点云分割方法。由混合概率主成分分析法构造的 M 个主成分分析器组成混合概率模型, 得到描述点云的邻接矩阵; 将点云分割的几何特征在谱空间进行降维嵌入, 利用 N-cut 方法得到描述点云分割特征的多维向量; 结合类间类内划分算法自适应分割点云。实验结果表明, 对于三种受测点云, 所提出的算法能在较宽预设参数范围内以 80% 以上概率得到收敛于几何特征的分割结果, 参数稳定性较好。在对点云添加均值为 0, 标准差为 0.01 的高斯噪声与 0.25 倍数量的离群点复合噪声的情况下, 算法表现出良好的抗噪性; 将该算法应用于切片式激光三维成像的卫星模型点云中也取得了理想分割结果。

关键词 成像系统; 三维成像; 点云分割; 混合概率主成分分析法; 谱聚类

中图分类号 TN249 文献标识码 A

doi: 10.3788/AOS201737.1011001

Mixed Manifold Spectral Clustering Adaptive Segmentation Method for Laser Point Cloud

Wang Shuai¹, Sun Huayan², Guo Huichao², Du Lin¹

¹Department of Postgraduate, Academy of Equipment, Beijing 101416, China;

²Department of Photoelectricity & Equipment, Academy of Equipment, Beijing 101416, China

Abstract The mixed manifold spectral clustering adaptive segmentation method is proposed, while the laser point cloud is regarded as a linear and nonlinear mixed manifold in three-dimensional Euclidean space. The mixture probabilistic model is constituted by M principal component analyzers, which are constructed by the mixtures of probabilistic principal component analysis method, and the adjacency matrix of point cloud is obtained. In the spectrum space, the geometrical characteristics of point cloud segmentation are embedded in the dimension, and the multi-dimensional vector, which describes the characteristics of point cloud classification, is obtained by N-cut method. The between-within proportion algorithm is adopted to segment point cloud adaptively. Experimental results show that the proposed algorithm can obtain segmentation results that converge to the geometric features with the probability larger than 80% in wide range of preset parameters. Moreover, it performs stable with Gaussian noises of 0 mean, 0.01 standard deviation and compound noise of 0.25 times the total points. The proposed method shows good noise resistance. It is applied to point cloud of satellite model acquired by slice laser three-dimensional imaging and achieves good segmentation results.

Key words imaging systems; three-dimensional imaging; point cloud segmentation; mixtures of probabilistic principal component analysis; spectral clustering

OCIS codes 110.2960; 100.4993; 150.6910

收稿日期: 2017-05-05; 收到修改稿日期: 2017-05-22

作者简介: 王 帅(1991—), 男, 博士研究生, 主要从事激光三维点云的重建与特征识别方面的研究。

E-mail: mage1120@foxmail.com

导师简介: 孙华燕(1963—), 女, 博士, 教授, 主要从事激光雷达设计与数据处理方面的研究。

E-mail: shy221528@vip.sina.com

1 引 言

激光三维成像是指系统主动发射激光照射目标,结合激光飞行时间或相位得到目标的三维点云。其具有距离远、精度高、不受光照影响等特点,可用于目标识别、逆向工程及相对导航等,具有很高的军事和民用应用价值。点云分割依据几何结构特征将目标点云分割为若干个有意义的部分,是点云处理的重要步骤,单个点云分割后可用于区域特征识别,两个部分重叠的点云分割后对应的重叠区域可用于点云配准。然而,受测距精度和后向散射等因素影响,激光三维成像得到的目标点云存在严重的高斯噪声和离群点,且目标复杂多样,无法预定义分割规则,这给激光三维成像的点云分割造成了一定的困难。

国内外学者对点云分割进行了大量研究,点云分割方式主要有:在空域依据点的局部几何特征连续性或相似性聚类,以及在频域依据点的局部几何特征相似性进行谱聚类。

Koschan^[1]采用区域生长方法分割点云,该方法对生长种子点的预设选取参数敏感;Rabbani 等^[2]依据点的法向量和曲率等局部几何特征连续性分割点云,其对含噪声点云表现不好。依据点的局部几何特征连续性的分割方法对噪声和预设参数较敏感,对激光点云的适用性并不好。

Shlafman 等^[3]较早将 k -means 聚类应用于点云分割;任同群等^[4]采用聚类方法将点云中非平坦区域作为匹配特征,拟合后实现点云配准;袁小翠等^[5]利用 k -means 聚类将点云分割为平坦区域和非平坦区域,实现了点云精简的密度自适应;卢维欣等^[6]将非地面点按照距离准则聚类分割,并对每个点云簇进行特征分析,实现了特征识别;王肖等^[7]在相对导航应用中采用聚类方法对象化分割目标点云,提高了效率和准确率;周文振等^[8]利用 k -means 聚类对迭代最近点配准算法(ICP)进行改进,完成了简单室内激光点云的配准。采用中心聚类的点云分割方法具有一定的抗噪性,在处理良分离目标应用中表现较好,但是依然存在对目标的几何结构解析能力较差的问题。

Golovinskiy 等^[9]借助谱聚类中的 Min-cut 准则实现了点云前景和背景的自适应分割;马腾等^[10]指出点在谱空间内能够表现出更好的类簇性,并使用归一化的几何矩和角度距离构造邻接矩阵,实现了谱聚类点云分割;韩丽等^[11]提取点的测地线等多特征构造邻接矩阵,并通过拉普拉斯矩阵特征值本征间隙自适应确定聚类数目,完成了点云的自适应分割。可见,谱聚类分割方法将点云特征转换到谱空间,保持了聚类算法一贯较好的抗噪优势,且从全局角度考虑分割问题,能更好地解析目标点云几何结构。

但目前的谱聚类分割方法大多依靠邻域点提取点的局部几何特征,在特征提取及分割数目自适应方面仍有改进空间。本文首先采用混合概率主成分分析(MPPCA)法提取点的局部几何特征构造邻接矩阵,然后利用 N-cut 实现点云特征降维嵌入,最后利用类间类内划分(BWP)算法进行自适应分割。

2 本文算法

点云的谱聚类分割是将点云 $\mathbf{X} \{x_1, x_2, \dots, x_N\}$ (N 为点云中点的数量)按照局部几何特征相似性分割为 k 类,同一类点的特征具有较大的相似性,而不同类点的特征具有较大的相异性。谱聚类分割步骤可分为:1)定义点的局部几何特征描述符,构造点云的邻接矩阵;2)利用拉普拉斯变化将点云的邻接矩阵映射到谱空间,降维得到描述每个点分割特征的低维向量;3)依据每个点的分割特征进行聚类,得到分割结果。

2.1 点的局部几何特征提取

点云谱聚类分割需要首先定义点的局部几何特征描述符,然后计算点云中所有点的局部几何特征之间的相似关系,构造邻接矩阵 $\mathbf{W}(i, j)$ ($i, j = 1, 2, \dots, N$) 表征点 x_i, x_j 之间的相似性,为了避免过拟合,一般认为点 x_i 仅与其最近邻点 k_{NN} 有关,将 $\mathbf{W}(i, j)$ 定义为

$$\mathbf{W}(i, j) = \begin{cases} p_{ij}, & x_i, x_j \text{ being nearest neighbor to each other} \\ 0, & \text{otherwise} \end{cases}, \quad (1)$$

式中 p_{ij} 为点 x_i, x_j 之间的局部几何特征相似性参数,一般情况下可由其邻域点局部采样协方差矩阵进行奇异值分解得到,或者用测地线及法向量等描述。但在点云分割的应用中,空间距离较近的点 x_i, x_j 对应邻域重合率很大,处于两个分割边界的点与周围相邻区域存在很大的相似性,极易出现过分割或欠分割;并且该方法容易受到邻域中噪声和离群点干扰,而对点云进行滤波处理后再分割则会对目标的细节造成一定影

响^[12],因此该特征提取方法并不完全适用于激光点云分割。

考虑到成像目标表面由平面和曲面构成,目标点云为分布于三维欧氏空间的点簇,从流形学习角度可以视点云为分布于三维空间的线性与非线性混合流形,不同的几何特征对应不同的流形结构,处于相同流形上的点几何特征相似,处于不同流形上的点几何特征不同。由此可以不依赖邻域点而完成点的局部几何特征描述,避免了基于邻域点的几何特征提取方法对噪声和参数的敏感性。

本文采用常用的流形学习方法——MPPCA^[13]分析点的局部几何结构特征,主要基于以下几个原因:1)非线性流形在局部可以被多个线性流形组合很好地近似表示^[14],因此其具备分析描述复杂几何结构点云的能力;2)点所在流形主子空间的主角度相似性能够描述点的局部几何特征相似性;3)MPPCA由主成分分析(PCA)法改进得到,具备PCA克服噪声影响提取主成分的能力,通过全局迭代最优解避免了PCA对邻域点选取的依赖,因此,MPPCA具备良好的抗噪性和对预设参数的稳定性。借助MPPCA将处于不同流形的点分离,利用点所在流形的几何特征描述点的几何特征,处于相似流形的点之间的 p_{ij} 较大,而处于不同流形的点之间的 p_{ij} 较小,这样可以得到符合目标几何结构特征的邻接矩阵。

MPPCA的主要思路是训练 M 个线性主成分分析器对每个点的局部几何结构进行估计,用最大期望(EM)算法得到最优描述点云分布的 M 个线性主成分分析器和每个点 x_i 对应的概率密度分布。假设在第 m 个线性主成分分析器中,每个点 x_i 对应于一个降维后的点 y_i ,则有

$$x_i = \mathbf{V}_m y_i + \mu_m + \epsilon_m, \quad (2)$$

式中 \mathbf{V}_m 为第 m 个分析器的主子空间, μ_m 为分布于第 m 个分析器的所有点均值, ϵ_m 为噪声。利用高斯混合模型将 y_i 和 ϵ_m 估计为 $y_i \sim N(0, I)$ 和 $\epsilon_m \sim N(0, \sigma_m^2 I)$, σ_m^2 为噪声标量。结合(2)式和贝叶斯公式,可得 x_i 关于 m 和 y_i 的条件分布为

$$p(x_i | y_i, m) = (2\pi\sigma_m^2)^{-3/2} \exp\left(-\frac{1}{2\sigma_m^2} \|x_i - \mathbf{V}_m y_i - \mu_m\|^2\right), \quad (3)$$

y_i 关于 m 的条件分布为

$$p(y_i | m) = (2\pi)^{-1} \exp\left(-\frac{1}{2} y_i^T y_i\right). \quad (4)$$

由(3)式和(4)式可得

$$p(x_i | m) = (2\pi)^{-3/2} |\sigma_m^2 I + \mathbf{V}_m \mathbf{V}_m^T|^{-1/2} \exp\left[-\frac{1}{2} (x_i - \mu_m)^T (\sigma_m^2 I + \mathbf{V}_m \mathbf{V}_m^T)^{-1} (x_i - \mu_m)\right]. \quad (5)$$

构造目标函数 ζ ,即第 m 个主成分分析器上所有点 x_i 的对数最大似然估计,得到

$$\zeta = \sum_{i=1}^N \ln \left[\sum_{m=1}^M \pi_m p(x_i | m) \right], \quad (6)$$

式中 π_m 为各个主成分分析器的混合比例, $\pi_m \geq 0$ 且 $\sum_{m=1}^M \pi_m = 1$ 。利用EM算法最大化目标函数 ζ ,即可得到各个主成分分析器的参数。EM算法主要为E步和M步两个部分的交替迭代,令第 t 次迭代的参数为 $\pi_m, \{\mathbf{V}_m, \mu_m, \sigma_m^2\}$,第 $t+1$ 次的估计值为 $\tilde{\pi}_m, \{\tilde{\mathbf{V}}_m, \tilde{\mu}_m, \tilde{\sigma}_m^2\}$,则有

1) E步

$$\tilde{\pi}_m = \left[\sum_{i=1}^N p(m | x_i) \right] / N, \quad (7)$$

$$\tilde{\mu}_m = \left[\sum_{i=1}^N x_i p(m | x_i) \right] / \sum_{i=1}^N p(m | x_i), \quad (8)$$

式中 m 对于 x_i 的后验概率分布为

$$p(m | x_i) = [\pi_m p(x_i | m)] / p(x_i); \quad (9)$$

2) M步

$$\tilde{\mathbf{V}}_m = \mathbf{S}_m \mathbf{V}_m (\sigma_m^2 I + T_m^{-1} \mathbf{V}_m^T \mathbf{S}_m \mathbf{V}_m)^{-1}, \quad (10)$$

$$\tilde{\sigma}_m^2 = \text{tr}[\mathbf{S}_m - \mathbf{S}_m \mathbf{V}_m T_m^{-1} (\tilde{\mathbf{V}}_m)^T] / 2, \quad (11)$$

其中

$$\mathbf{S}_m = \left[\sum_{i=1}^N p(m | x_i) (x_i - \tilde{\mu}_m) (x_i - \tilde{\mu}_m)^T \right] / (N \tilde{\pi}_m), \quad (12)$$

$$T_m = \sigma_m^2 I + \mathbf{V}_m^T \mathbf{V}_m. \quad (13)$$

σ_m^2 的初始化参数为高斯分布中的随机数, π_m 的初始化参数为均匀分布, μ_m 的初始化参数由数次 k -means 迭代得到。当两次迭代之间的参数变化小于预设值时, 认为算法收敛, 此时得到的参数即为 M 个主成分分析器的参数以及 x_i 对应的概率密度分布。将概率最大的主成分分析器作为点的所在流形, 则点 x_i , x_j 之间的相似关系为^[15]

$$p_{ij} = \prod \text{svd}(\mathbf{V}_{m_{x_i}}^T \mathbf{V}_{m_{x_j}}). \quad (14)$$

至此, 由(14)式结合(1)式即可得到点云中各点基于 MPPCA 的邻接矩阵 \mathbf{W} 。

2.2 特征的谱空间低维嵌入

得到邻接矩阵 \mathbf{W} 后, 采用谱聚类方法进行切割, 以子类内部相似且子类之间距离较远为切割准则。作为一种基于图论的聚类方法, 谱聚类可以构造一个全局评价函数, 并得到分割最优解, 具体方法有 Min-cut、Ratio-cut 及 N-cut 等, 其中, N-cut 最常用且表现最好, 其评价函数为^[16]

$$N_{\text{cut}}(A_1, A_2, \dots, A_k) = \sum_{l=1}^k \left[\sum_{x_i \in A_l, x_j \in \bar{A}_l} \mathbf{W}(i, j) / \sum_{x_i \in A_l, x_j \in X} \mathbf{W}(i, j) \right], \quad (15)$$

式中 A_l ($l=1, 2, \dots, k$) 为第 l 个子类, \bar{A}_l 为 A_l 的补集。该评价函数中的惩罚因子包含了对子类数目的约束, 避免孤立点形成子类, 所以能使分割结果中子类数目较平均, 且能够结合非规范化拉普拉斯矩阵 \mathbf{L} , 将 NP-complete 问题松弛化后转化为 P 问题。 \mathbf{L} 定义为 $\mathbf{L} = \mathbf{D} - \mathbf{W}$, 其中, 对角矩阵 \mathbf{D} 为待切割图的度矩阵, 对角元素定义为 $d_i = \sum_{j=1}^N \mathbf{W}(i, j)$ 。根据拉普拉斯矩阵的性质可知, 最小化 N-cut 值的问题可以转化为最小化 \mathbf{L} 矩阵的特征值 λ 的问题, 即取 \mathbf{L} 矩阵的前几个最小特征值。从第二小特征值开始, 每个特征值对应的特征向量均可表示点的分类关系。按照对应特征值由小到大从第二个特征向量开始, 取 q 个特征向量, q 值由矩阵最大本征间隙决定, 将 q 个 N 维特征向量构成 $N \times q$ 矩阵, 矩阵中第 i 行的 q 维向量即对应点 x_i 的分割特征描述符。

谱聚类把点云转换到谱空间, 并在谱空间对点云进行分析, 然后将分割特征描述符嵌入低维向量, 相较于直接对矩阵 \mathbf{W} 进行聚类分割, 谱空间能够更好地表达点云类别特征, 得到更好的聚类结果。

2.3 自适应分割

点云分割过程期望实现无监督分割, 即根据点云的几何结构自适应分为 k 类。为此, 结合 BWP 算法实现点云分割中分类数 k 的自适应选择^[17]。BWP 算法根据子类距离构建对聚类结果的评价函数, 并对一定范围内的 k 值聚类结果进行评价, 将评价结果最优的 k 值作为自适应分割的最优 k 值。具体表达式为

$$B_{\text{WP}}(l, i) = [b(l, i) - \omega(l, i)] / [b(l, i) + \omega(l, i)], \quad (16)$$

式中 $b(l, i)$ 和 $\omega(l, i)$ 分别为第 l 个子类中点 x_i 的最小类间距离和所有点的平均距离, 两者定义分别为

$$b(l, i) = \min_{1 \leq g \leq k, g \neq l} \left(\sum_{j=1}^{N_g} \|x_j - x_i\|^2 / N_g \right), \quad (17)$$

$$\omega(l, i) = \sum_{p=1, p \neq i}^{N_l} \|x_i - x_p\|^2 / (N_l - 1), \quad (18)$$

式中点 x_p 为第 l 个子类中不同于 x_i 的点, N_l 为第 l 个子类中点的数量, 点 x_j 为第 g 个子类中的点, N_g 为第 g 个子类中点的数量。BWP 算法能够按照子类内部相似且子类之间距离较远的标准评价聚类结果, BWP 值越大说明聚类效果越好。在合适的评价指标之下, 将分割的子类数 k 限定在 $[k_{\min}, k_{\max}]$, 对每一个 k 值, 计算当前点云中所有点的 BWP 均值

$$k_{\text{BWP_avg}} = \sum_{l=1}^k \sum_{i=1}^{N_l} B_{\text{WP}}(l, i) / N, \quad (19)$$

在 k 的取值范围内, 满足 $k_{\text{BWP_avg}}$ 取最大值的 k 值即为最佳聚类参数, 对应的聚类结果即为点云的最佳分割结果。

3 实验与分析

3.1 仿真点集测试与分析

为了体现本文算法在全局角度分析目标几何结构的能力, 分别利用二维空间中两条螺旋线合成的二维点集和三维空间中相交的两条直线及一个平面合成的三维点集对算法进行测试, 结果如图 1 所示。可以看

出,本文算法没有在局部曲率变化最大的地方切割点集,而是考虑了几何结构的连续性,从全局结构进行了切割,这一特征使得该算法能够更好地体现目标的几何结构,而不是单纯地依靠曲率变化等局部特征进行分割,该切割方式更符合对目标的结构认知。




图 1 仿真点集的分割结果。(a)两条曲线构成的螺旋线;(b)相交的直线与平面

Fig. 1 Segmentation results of simulated point sets. (a) Spirals made by two curves; (b) crossed lines and plane

3.2 算法主要参数分析

需要预设的主要参数为主成分分析器数量 M 和近邻点数 k_{NN} 。预设参数的调节是点云分割的一大难题,根据目标点云调节参数会带来巨大的工作量,自适应点云分割期望在较宽预设参数范围内得出理想的分割结果,本文参数分析部分主要考察算法对预设参数的稳定性。实验采用了三组激光点云 Rabbit、Horse 和 Armadillo^[18-20]对算法进行测试。图 2 所示的分割结果为实验中出现最多的结果,即本文算法收敛于全局最优解时得到的分割结果,可以看出,该结果较好地符合目标几何结构。但是不同的参数会影响得到此结果的概率。当参数不合适时,自适应分割结果会收敛于存在严重分割错误的局部最优解。以图 2 所示的结果为基准,由分割结果一致性评价算法对参数的稳定性,其中分割结果一致性为算法在不同参数条件下收敛于全局最优解的概率。




图 2 符合目标点云几何结构的分割结果。(a) Rabbit; (b) Horse; (c) Armadillo

Fig. 2 Segmentations of point clouds based on target geometry. (a) Rabbit; (b) Horse; (c) Armadillo

实验过程如下:首先选出一组分割结果一致性较好的 M 和 k_{NN} ,固定 k_{NN} ,将 M 以 5 为步长在 5~100 之间变化,若分割结果与图 2 中分割数目相同且各部分点与点对应比例均在 95% 以上,则认为该分割结果与图 2 结果一致,测试结果记为 1,反之则记为 0。由于 MPPCA 中的 EM 学习是迭代最优化的,因此完全相同参数条件下分割结果也有可能不同,故对每个 M 值进行 100 次重复实验,统计测试结果为 1 的百分比,将其作为当前 M 值的一致性评价标准。 k_{NN} 的测试按相似的方式进行。

1) 分割结果一致性与 M 的关系

M 值与目标的复杂程度有关,需要对目标进行具体的调试才能得到最佳值。但是从图 3 可以看出,在 M 值偏小或偏大不严重的情况下,本文算法均能得到较理想的结果。其中 Rabbit 由于结构明显,在合适的 M 取值情况下,分割结果的一致性达到了 100%,Horse 和 Armadillo 的分割结果一致性也均达到了 80% 以上。但 M 的取值和分割结果一致性并不成正相关,这是因为适当数量的主成分分析器已经可以较好地描述点云结构, M 过大会造成点云中的点在众多主成分分析器上分布过于离散,点与点之间的几何结构关系提取不准确。

同时, M 值与 EM 算法中的混合概率模型复杂程度有关,其对程序运行时间会造成影响,测试结果如图 4 所示。其中 Rabbit、Horse、Armadillo 图中三维点数量分别为 3921、5091、5370。综上,推荐 M 值大于 30 即可。

2) 分割结果一致性与 k_{NN} 的关系

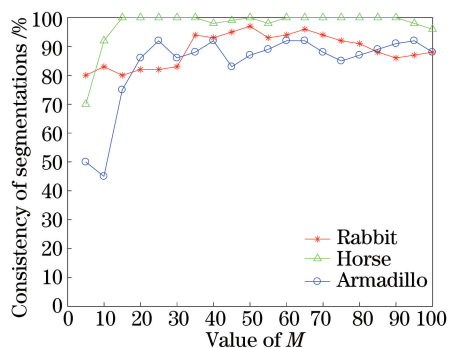


图 3 点云分割结果一致性与 M 之间的关系

Fig. 3 Relationship between consistency of segmentation and M

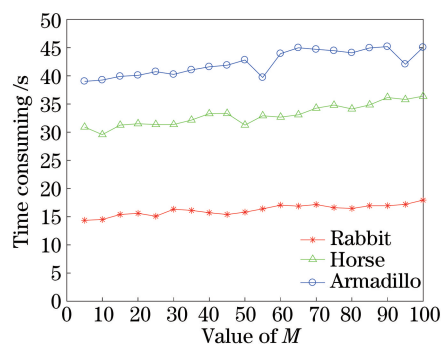


图 4 程序运行耗时与 M 之间的关系

Fig. 4 Relationship between time consuming and M

点的局部几何结构由 M 个主成分分析器的混合概率描述,与 k_{NN} 的取值没有直接关系。但是为了避免欠分割或将局部几何结构相似而不相邻的点分割到一个部分,将 $W(i, j)$ 在 x_i, x_j 不互为 k_{NN} 点时赋值为 0。因此, k_{NN} 值与分割结果一致性也存在一定的相关性,测试结果如图 5 所示。可见该算法对 k_{NN} 的取值也存在较大的宽容度。

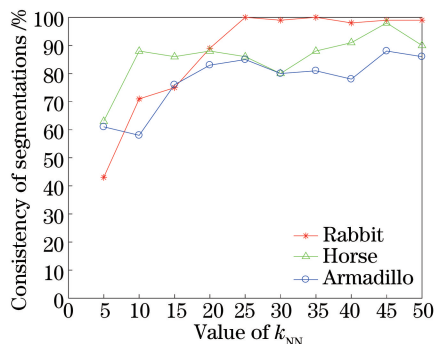


图 5 点云分割结果一致性与 k_{NN} 之间的关系

Fig. 5 Relationship between consistency of segmentation and value of k_{NN}

综上所述,算法在较宽的参数范围内能得到符合目标几何特征的全局最优解。虽然不适当的参数会影响得到正确结果的概率,但仍然可以通过多次运行得到最大概率下点云的正确分割。

3.3 点云测试与分析

受测距精度和后向散射等因素影响,激光点云一般存在高斯噪声严重且离群点较多的情况。为了测试算法在激光点云分割中的应用效果,分别对添加噪声的仿真数据和真实数据进行测试。

1) 添加高斯噪声和离群点的仿真点云分割

根据激光点云的噪声特性,对三种点云添加均值为 0,标准差为点云最小外包盒对角线的 0.01 倍的噪声,并且额外添加数量为点数 0.25 倍的离群点,得到待测试点云如图 6(a)所示,分别利用基于 k -means 的聚类分割算法^[3]、基于局部角距离的谱聚类分割算法^[21]以及本文算法,重复实验后选取出现次数最多的结果作为最终结果,如图 6(b)~(d)所示。

从图 6(b)可以看出,基于 k -means 的分割算法没有得到正确的分割结果,这是因为基于 k -means 的分割算法受到点的距离影响较严重,对点云几何结构解析能力较差;从图 6(c)可以看出,基于局部角距离的谱聚类分割算法在 Rabbit 点云中得到了错误的分割结果,且在 Armadillo 点云中中对分割边界等细节的处理仍有一定欠缺,这是因为基于局部角距离提取特征会使得分割结果在本属于一个连续部分但曲率变化较大时容易断开,且在受到噪声干扰时不能准确解析几何特征;而本文算法在三种点云中均表现良好。

2) 切片式激光三维成像的真实点云分割

结合基于距离选通切片式激光三维成像得到的卫星模型点云进行实验,目标的灰度图像如图 7(a)所示;切片式激光三维成像的点云具有激光三维成像的主要特征,即点云存在严重的噪声和大量离群点,

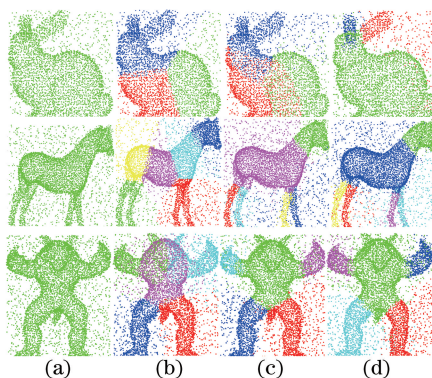


图 6 不同分割算法对含噪声的点云图像的分割结果。(a)添加噪声的点云;(b) k -means 算法;
(c)局部角距离谱聚类算法;(d)本文算法

Fig. 6 Segmentation results of point clouds with noises by different segmentation algorithms. (a) Point cloud with noise;
(b) k -means algorithm; (c) local angular distance spectral clustering algorithm; (d) proposed algorithm

图 7(b)为目标点云侧视图;本文没有对点云进行去噪处理,直接对图 7(b)中点云进行分割,结果如图 7(c)、(d)所示,可见在点云受到严重噪声干扰的情况下,本文算法依然准确提取出了目标的结构特征,将卫星模型的目标点云分为了实验舱、左右太阳能电池板以及航天员模型,符合模型实际特征,且分割边界良好,充分说明本文算法对激光点云的自适应性。

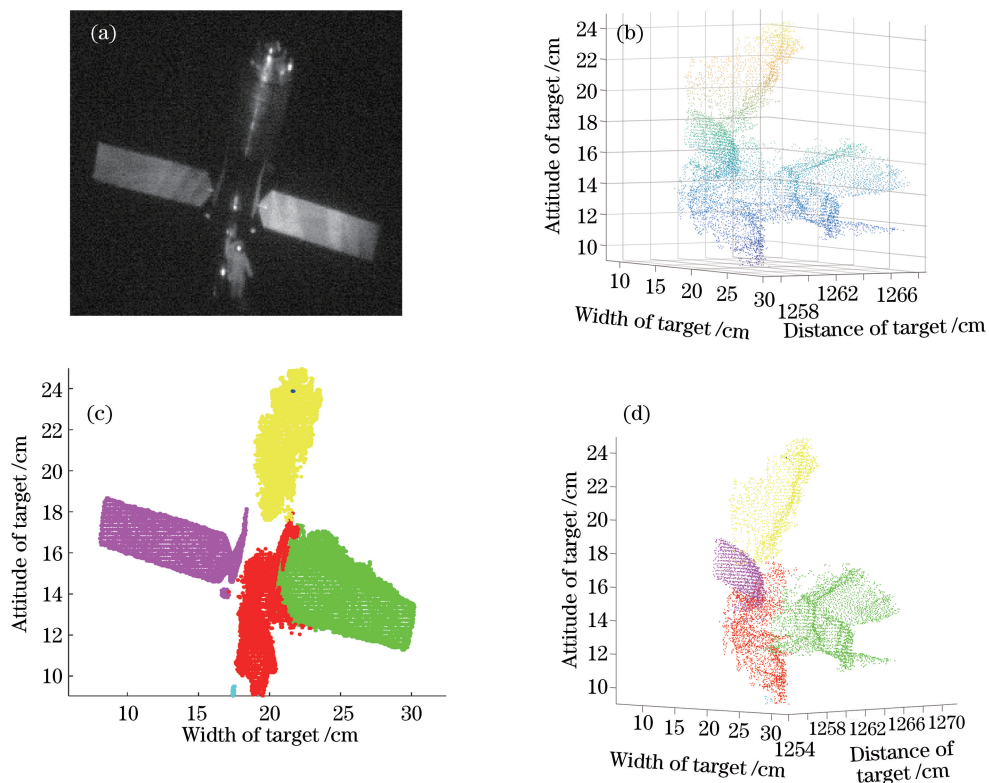


图 7 卫星模型点云的分割结果。(a)灰度图像;(b)切片式三维成像法得到的侧视图;(c)本文算法得到的正视图;
(d)本文算法得到的侧视图

Fig. 7 Segmentation results of point cloud of satellite model. (a) Gray image; (b) side view of slice
three-dimensional imaging; (c) front view of segmentation by the proposed algorithm;
(d) side view of segmentation by the proposed algorithm

4 结 论

结合激光点云的特点,提出了一种基于混合流形谱聚类的激光点云自适应分割方法,该算法具有良好的结构分析能力和抗噪性。实验结果表明,本文算法对预设参数稳定性好,在较宽参数范围内对三种受测点云均能得到以 80% 以上概率收敛于合理分割的结果。且在高斯噪声和离群点干扰的情况下表现稳定,适合于激光点云的自适应分割。对切片式三维成像点云进行分割,也取得了较好的结果。

本文算法仍然存在一些不足,例如对较复杂的非线性流形构成的混合点云分割准确率会有所下降,因此还待进一步改进。本文算法得到的分割结果可用于激光点云的配准与目标特征识别,对分割结果的应用也有进一步研究的价值。

参 考 文 献

- [1] Koschan A F. Perception-based 3D triangle mesh segmentation using fast marching watersheds[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2003: 27-32.
- [2] Rabbani T, Van Den Heuvel F, Vosselman G. Segmentation of point clouds using smoothness constraint [J]. International Archives of Photogrammetry, Remote Sensing & Spatial Information Sciences, 2006, 36(5): 248-253.
- [3] Shlafman S, Tal A, Katz S. Metamorphosis of polyhedral surfaces using decomposition [C]. Computer Graphics Forum, 2002, 12(3): 219-228.
- [4] Ren Tongqun, Zhao Yuehan, Gong Chunzhong, *et al.* Unconstrained registration of 3-D scattered point clouds for free-form shape measurement [J]. Optics & Precision Engineering, 2013, 21(5): 1234-1243.
任同群, 赵悦含, 龚春忠, 等. 自由曲面测量的三维散乱点云无约束配准 [J]. 光学 精密工程, 2013, 21(5): 1234-1243.
- [5] Yuan Xiaocui, Wu Lushen, Chen Huawei. Feature preserving point cloud simplification [J]. Optics and Precision Engineering, 2015, 23(9): 2666-2676.
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.
- [6] Lu Weixin, Wan Youchuan, He Peipei, *et al.* Extracting and plane segmenting buildings from large scene point cloud [J]. Chinese J Lasers, 2015, 42(9): 0914004.
卢维欣, 万幼川, 何培培, 等. 大场景内建筑物点云提取及平面分割算法 [J]. 中国激光, 2015, 42(9): 0914004.
- [7] Wang Xiao, Wang Jianqiang, Li Keqiang, *et al.* Fast segmentation of 3-D point clouds for intelligent vehicles [J]. Journal of Tsinghua University (Science and Technology), 2014, 54(11): 1440-1446.
王肖, 王建强, 李克强, 等. 智能车辆 3-D 点云快速分割方法 [J]. 清华大学学报(自然科学版), 2014, 54(11): 1440-1446.
- [8] Zhou Wenzhen, Chen Guoliang, Du Shanshan, *et al.* An improved iterative closest point algorithm using clustering [J]. Laser & Optoelectronics Progress, 2016, 53(5): 051202.
周文振, 陈国良, 杜珊珊, 等. 一种聚类改进的迭代最近点配准算法 [J]. 激光与光电子学进展, 2016, 53(5): 051202.
- [9] Golovinskiy A, Funkhouser T. Min-cut based segmentation of point clouds [C]. IEEE International Conference on Computer Vision Workshops (ICCV), 2009: 39-46.
- [10] Ma Teng, Long Xiang, Feng Lu, *et al.* Point cloud segmentation based on spectral clustering [J]. Journal of Computer-Aided Design & Computer Graphics, 2012, 24(12): 1549-1558.
马腾, 龙翔, 冯路, 等. 点云模型的谱聚类分割 [J]. 计算机辅助设计与图形学学报, 2012, 24(12): 1549-1558.
- [11] Han Li, Xu Jianguo, Li Lin, *et al.* 3D shape analysis based on Laplacian multi-eigenmap [J]. Journal of Computer-Aided Design & Computer Graphics, 2015, 27(11): 2142-2148.
韩丽, 徐建国, 黎琳, 等. Laplacian 多特征映射的三维模型形状分析 [J]. 计算机辅助设计与图形学学报, 2015, 27(11): 2142-2148.
- [12] Aiger D, Mitra N J, Cohen-Or D. 4-points congruent sets for robust pairwise surface registration [J]. ACM Transactions on Graphics (TOG), 2008, 27(3): 85.
- [13] Tipping M E, Bishop C M. Mixtures of probabilistic principal component analyzers [M]. Jordan M I, Sejnowski T J. Cambridge: MIT Press, 2001: 167-206.
- [14] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323.

-
- [15] Zhang Xianda. Matrix analysis and applications[M]. 2nd ed. Beijing: Tsinghua University Press, 2013: 483-491.
张贤达. 矩阵分析与应用[M]. 2 版. 北京: 清华大学出版社, 2013: 483-491.
- [16] Shi J, Malik J. Normalized cuts and image segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 22(8): 888-905.
- [17] Zhou Shibing, Xu Zhenyuan, Tang Xuqing. New method for determining optimal number of clusters in K-means clustering algorithm[J]. Journal of Computer Applications, 2010, 30(8): 1995-1998.
周世兵, 徐振源, 唐旭清. K-means 算法最佳聚类数确定方法 [J]. 计算机应用, 2010, 30(8): 1995-1998.
- [18] Krishnamurthy V, Levoy M. Fitting smooth surfaces to dense polygon meshes[C]. ACM Proceeding of the 23rd Annual Conference on Computer Graphics and Interactive Techniques, 1996: 313-324.
- [19] Turk G, Levoy M. Zippered polygon meshes from range images[C]. ACM Proceeding of the 21st Annual Conference on Computer Graphics and Interactive Techniques, 1994: 311-318.
- [20] Lai K, Bo L, Ren X, *et al.* A large-scale hierarchical multi-view RGB-D object dataset [C]. IEEE International Conference on Robotics and Automation, 2011: 1817-1824.
- [21] Hoppe H, Derose T, Duchamp T, *et al.* Surface reconstruction from unorganized points[C]. ACM Proceedings of the 19th Annual Conference on Computer Graphics and Interactive Techniques, 1992: 71-78.