

一种鲁棒的飞机零件多尺度特征点检测方法

李红卫¹, 魏泽勇²

(1. 中航西安飞机工业集团股份有限公司, 西安 710089; 2. 南京航空航天大学计算机科学与技术学院/人工智能学院, 南京 211106)

摘要: 针对飞机零件几何模型多尺度特征检测问题, 提出一种鲁棒的多尺度特征点检测算法。算法首先设计一种 L_1 中值滤波算法获取无结构点云精准法线; 然后基于计算得到的法线, 计算各点的局部邻域波动, 提取初始特征点; 最后针对初始特征点数据冗余问题, 提出一种收缩优化策略, 计算最终特征数据点。试验结果表明, 与传统的点云特征点检测方法相比, 算法检测精度明显提升; 其次, 对于存在较大噪声的点云数据仍然能够有较好的提取效果, 算法鲁棒性高。

关键词: 点云模型; 飞机零部件; L_1 中值法向量滤波; 收缩优化

中图分类号: TP391 **文献标志码:** A **文章编号:** 1005-2615(2021)05-0813-08

Robust Scheme for Multi-scale Features Detection from Aircraft Parts

LI Hongwei¹, WEI Zeyong²

(1. AVIC Xi'an Aircraft Industry Group Company Ltd., Xi'an 710089, China; 2. College of Computer Science and Technology/ College of Artificial Intelligence, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China)

Abstract: Aiming at the problem of multi-scale feature detection of aircraft part geometric models, a robust multi-scale feature point detection algorithm is proposed. The algorithm first designs a median filter algorithm to obtain the precise normals of unstructured point clouds. Then the local neighborhood fluctuations of each point is calculated based on the calculated normals, and the initial feature points is extracted. Finally, for the data redundancy of the initial feature points, a shrinkage optimization strategy is proposed to calculate the final feature data points. Experimental results show that compared with the traditional point cloud feature point detection method, the algorithm proposed in this paper has significantly improved detection accuracy. Secondly, this method is able to extract precise feature points, even when the input is corrupted by heavy noise.

Key words: point cloud model; aircraft component; L_1 -median normal filtering; shrink optimization

随着数字化制造模式的全面推广应用, 飞机制造中小应力、无余量装配已成为常态, 零部件的制造精度直接关系到飞机产品的质量和寿命。如何保证每个零部件的制造精度越来越受到重视^[1-2]。目前国内对于复杂零部件的检测, 大多采用三坐标测量机, 这种方法检测精度高, 但是由于采用了接触式测头, 存在测端半径补偿误差, 尤其对于结构

复杂且体积较大的零部件, 不但检测效率更低, 而且定位困难^[3], 难以快速准确地测量。实际中, 部件或一些超大型零件甚至因几何尺寸超出测量机的有效工作范围而无法使用测量机测量。随着三维扫描技术和计算机技术的发展^[4-6], 点云数据处理技术越来越受到几何测量领域的关注, 基于点云数据的模型构建与数字化分析模式日益成为机

收稿日期: 2020-03-20; 修订日期: 2020-09-29

通信作者: 李红卫, 男, 硕士, 副总工程师, E-mail: 1063678829@qq.com。

引用格式: 李红卫, 魏泽勇. 一种鲁棒的飞机零件多尺度特征点检测方法[J]. 南京航空航天大学学报, 2021, 53(5): 813-820. LI Hongwei, WEI Zeyong. Robust scheme for multi-scale features detection from aircraft parts[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2021, 53(5): 813-820.

械零部件检测技术的研究方向。该模式利用激光等波束的扫描,通过对发射波束和回波接收的时间差、方位角度差值的采集以及对距离、方位的计算分析,可以获得高精度、高密度的三维扫描点云数据,继而在对点云数据进行分析处理的基础上,提取零部件几何特征,以实现零部件实际几何形位的定量分析及特征的逆向重构。

点云数据的特征可以反映模型的外形和基本结构^[7-8],并且包含了模型很多重要信息,因此提取模型的特征在几何分析、曲面重建与编辑以及孔洞修补等方面有着广泛的应用。如何准确、快速检测出点云模型的特征点,国内外专家开展了大量深入的研究。目前针对点云特征点提取的方法一般分为3类:(1)基于点云法向量,曲率及投影等几何特征的方法^[9-11];(2)基于主成分分析(Principal components analysis, PCA)的方法^[12-14];(3)基于映像和模型构建的特征点提取方法^[15-16]。

对于基于曲率、法向量以及投影等几何特征的方法, Liu 和 Jin^[17]构建多尺度算子,在每个点的多个邻域范围内计算法线的差来识别位于特征区域的点。Kim^[18]利用近似移动最小二乘法来拟合局部平面,通过拟合的多项式方程及其导数来估计给定邻域范围内的曲率,然后构建 Voronoi 图来获取邻域点的信息,从而提取出谷脊点,但是这种方法不适用于只包含少量邻域点的尖锐点处,并且算法耗时长。

针对基于主成分分析的方法, Gumhold 等^[19]首先构建泰森多边形获取邻域信息,再采用 PCA 方法,根据求解协方差矩阵的特征值之间比例关系将点分为面点、边点和角点,进而判断点云中各点是否属于特征线。上官宁和刘斌^[20]通过主成分分析的方法获得主轴方向,沿着特征点的生长方向寻找后续特征点,从而实现特征线的提取。Pauly 等^[21]引入多尺度分析,首先使用基于局部邻域的协方差分析方法标记出潜在的特征点,再变换邻域半径,从而可以多尺度地处理含有噪声的模型。该类方法利用协方差分析点归属不同特征的概率,但是无法实现对目标物突兀区域特征线的判断。

对于基于映像和模型构建的特征点提取方法, 庞旭芳等^[22]首先拟合曲面多项式,并计算点云每个点的主曲率,将主曲率绝对值较大的点标记为潜在谷脊特征点,通过协方差分析计算谷脊特征点在一定邻域范围内的主轴方向,再将潜在谷脊点投影得到平滑的谷脊线。Weber 等^[23]首先在邻域范围内构建高斯图,根据邻域范围内法线变化度来进行高斯映射聚类,依据每个点所属类别的个数判别特征点。但是该方法对于平缓过渡的特征信息不够

敏感,无法提取强度渐变的特征信息。

由上述分析可知,第1类及第3类方法大多采用了局部曲面拟合或重建的策略,这类方法对噪声敏感,鲁棒性差并且计算复杂度较高。此外,由于模型中多尺度特征的曲率、法向量变化多样,采用此类方法检测是不准确的或者很难区分开非特征点与特征点。同时第2类基于 PCA 方法主要依靠协方差分析,然而协方差分析对模型微分性质的敏感度有限,无法提取细小的特征。综上所述,现有算法对于点云模型的轮廓线、棱线等(大尺度特征)提取效果较好,但是不能处理模型多尺度特征的情况。

为此,本文提出了基于邻域波动的点云多尺度特征提取方法。首先利用 PCA 的原理计算法线,并对法线进行 L_1 中值法向量滤波,再根据滤波后的法线计算局部坐标系,基于局部坐标系计算各点的邻域波动,统计分析模型的波动性分布情况,提取初始特征点,最后对初始特征点进行收缩优化,得到清晰完整的特征点。该算法较之已有算法有以下优点:(1)利用 L_1 中值原理,在去除噪声的同时,保持模型的多尺度特征;(2)针对初始特征点冗余问题,提出了一种迭代收缩优化策略,可以得到清晰完整的特征点;(3)算法计算复杂度小,处理效率高,对噪声鲁棒。

1 算法描述

三维模型的特征点是指视觉上体现模型形状特性的点集,主要包含多尺度尖锐棱边点、谷脊点。多尺度在于特征的曲率范围和几何尺寸范围。给定的一个不含有法向信息的点云模型, n 为点云中数据点的个数。本文算法旨在检测输入模型 P 的多尺度特征,提取清晰完整的特征点。

本文针对飞机零部件的点云模型提出一种多尺度特征检测算法,首先对点云模型进行 L_1 中值法向量滤波,得到特征明显的法向量场;然后计算各点的邻域波动情况,统计分析整体模型的波动性分布,提取初始特征点集;最后对初始特征点进行收缩优化,得到最终的清晰完整的特征点。

1.1 L_1 中值法向量滤波

在获取点云数据的过程中,受到周围环境因素的影响,例如物体遮挡,被测物体的细微震动等,或人为因素的影响,例如不正确的测量方法,都会给测量获取的点云数据带入噪声。这些噪声会使得点云模型的几何特征变得不明显。而法线是点云模型的一个重要的几何特征,准确的法线可以更精准地描绘模型的特征。因此,在进行特征提取前,

本文算法首先对输入点云的法向量场进行滤波,使其恢复出不受噪声干扰、特征清晰的法向量场。

确定点云每个点的法线问题可以简化为估计过该点与点云表面相切的平面法线问题,因此估计点云每个点的法线问题就变成在一定邻域范围内估计最小二乘平面拟合的问题,Hoppe等^[24]首先在表面重建中提出了这种方法——PCA法。主成分分析法将 n 维特征映射到 k 维上,就是从原始空间中顺序地找出一组相互正交的坐标轴,最终化简为对一个协方差矩阵的特征向量和特征值的分析。给定一组点云数据 $P=\{p_1, p_2, \dots, p_n\}$,对于每个点 p_i ,其协方差矩阵为

$$C_i = \frac{1}{k} \sum_{j \in \Omega_i} (p_j - \bar{p}_i)(p_j - \bar{p}_i)^T \quad (1)$$

式中: $\bar{p}_i = \frac{1}{k} \sum_{j \in \Omega_i} p_j$, p_j 是 p_i 的 r 半径近邻点,即 p_j 位于以 p_i 为中心, r 为半径的球内。计算协方差矩阵 C_i 的特征值,按从大到小排序,取最小特征值对应的特征向量作为求解的法向量 n_i ,对每个点依此遍历,得到点云 P 的法向量场 $N=\{n_1, n_2, \dots, n_n\}$ 。

但由于PCA算法的低通特性,计算出的法线在尖锐特征处过于光滑,不能保持模型的尖锐特征,从而增加了模型的特征提取难度。如图1所示,双边滤波虽然在保持边缘尖锐特征方面有一定效果,但是对多尺度特征却表现不佳,而 L_1 中值滤波却可以很好地保持多尺度特征。因此,本文在计算局部波动性前,先使用 L_1 中值对模型进行法向量滤波。

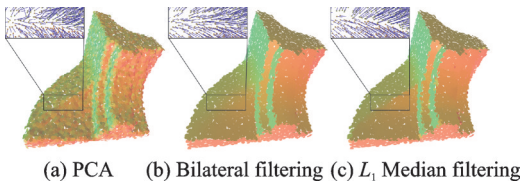


图1 PCA、双边滤波与 L_1 中值滤波法向量对比图

Fig.1 Comparison of normal results computed by PCA, bilateral filtering, and L_1 median filtering

一个点集的 L_1 中值可理解为:对于任意一个点集,存在一点 x ,使得该点到点集 P 中所有点的欧式距离之和最小,即 $\arg \min_x \sum_{i \in I} \|x - p_i\|_2$ 。通俗来讲, L_1 中值就是取一列有序数的中位数,相对于 L_2 平均值来说更能剔除异常值,映射到点云中,也就是对噪声更鲁棒,可以使选取出的投影点不受异常值或噪声的影响,更能体现模型的特征。

为得到在特征区域有明显区分的法向量场,本章算法将 L_1 中值原理应用于本文算法的法向量滤

波任务中,通过衡量点 p_i 以及其邻点 p_j 之间的法线差异, L_1 中值法向量滤波可表示为

$$\sum_{j \in \Omega_i} w\left(\frac{1 - \cos(\theta_{ij})}{1 - \cos(\sigma_r)}\right) w\left(\frac{\|p_i - p_j\|}{\sigma_s}\right) \|n_i - n_j\|_2 \quad (2)$$

式中: Ω_i 为点 p_i 的 r 半径邻域, $w(\cdot)$ 为高斯权重函数, θ_{ij} 表示点 p_i 与点 p_j 的法线夹角, σ_s 表示目标点 p_i 到邻点 p_j 的距离对点 p_i 的影响因子, σ_s 越大,点云越光滑,但保持特征的能力越差; σ_r 表示 n_i 与 n_j 之间的夹角对 n_i 的影响, σ_r 越小,保持特征能力越好。

由于式(2)是非线性的,进行优化求解会比较困难,于是本文提出了一种优化的迭代形式。将式(2)对 n_i 进行求导,并令其等于零,可得到

$$n_i^{t+1} = \frac{\sum_{j \in \Omega_i} w_{ij} n_j^t}{\sum_{j \in \Omega_i} w_{ij}} \quad (3)$$

式中 n_i^{t+1} 表示点 p_i 在第 $t+1$ 次迭代得到的法线。

$$w_{ij} = \frac{w\left(\frac{1 - \cos(\theta_{ij})}{1 - \cos(\sigma_r)}\right) w\left(\frac{\|p_i - p_j\|}{\sigma_s}\right)}{\|n_i - n_j\|_2} \quad (4)$$

当 $n_i = n_j$ 时,式(4)分母为0,没有意义,因此,为避免这种情况,当 $\|n_i - n_j\| < 10^{-3}$ 时,本文将上式的权重替换为双边滤波权重,即

$$w_{ij} = w\left(\frac{1 - \cos(\theta_{ij})}{1 - \cos(\sigma_r)}\right) w\left(\frac{\|p_i - p_j\|}{\sigma_s}\right) \quad (5)$$

1.2 局部邻域波动估计

基于滤波后的法线,本文将对每个点局部波动性 $\Delta=\{\delta_1, \delta_2, \dots, \delta_n\}$ 的计算方法进行详细介绍。首先,将目标点以及其 r 邻域点投影到目标点的法向量上,即将目标点的法线作为基准向量,得到目标点及其邻域点在其基准向量上的局部坐标值,然后将目标点与其邻点的局部坐标值作差,得到两点之间的差异

$$\delta_{ij} = |p_i \cdot n_i^{tT} - p_j \cdot n_i^{tT}| \quad (6)$$

式中 δ_{ij} 表示点 p_i 与 p_j 在基准向量 n_i^{tT} 上的距离。波动性计算如图2所示。

其次,找出 δ_{ij} 的最大值,即找出点 p_i 与其 r 半径邻域内所有点中波动性最大的值;最后,将最大差异值作为目标点的局部波动性值,即

$$\delta_{ij} = \max_{j \in \Omega_i} \delta_{ij} \quad (7)$$

遍历所有点,得到每个点的局部波动性。

与传统的提取特征方法如计算曲率、法线夹角等相比,本文选择通过在法向量上度量各点的波动性,其原因如下。

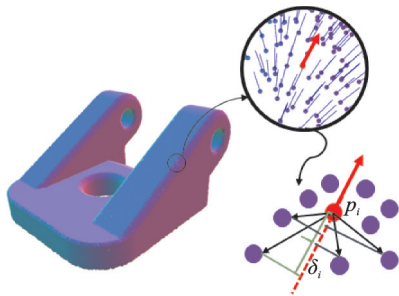


图2 波动性计算示意图

Fig.2 Illustration of local surface variation

多尺度特征中的小尺度特征相比于整个模型的尺度非常小,而曲率计算的思路一般是对点 p_i 与其邻域点 p_j 组成的局部点云做最小二乘拟合,解得系数后根据空间曲面曲线的性质计算数据点的高斯曲率、平均曲率。局部邻域中某些点计算出的曲率可能会比较大,这些点会被认为是特征点。但是在整体模型的视角,一个目标点的 r 邻域相对整个模型是非常小的,这些被误判的特征点的变化可能只是零件表面不光滑导致的,而并非是特征点。因此,通过计算曲率提取特征点的方法是不可行的。对于小尺度特征,因PCA算法不能捕捉细小的特征,所以通过该方法计算出来的法线并不准确,也就不能够通过法线的变化准确地判断出特征点的位置。在得到所有点的局部波动性 Δ 后,统计分析波动性的分布区间,设定波动性阈值 ω ,若 δ_i 大于 ω ,则认为点 p_i 为初始特征点;反之,则为非特征点。波动性阈值的取值与点云数据要提取的特征尺度密切相关,对于大尺度特征可以将波动性阈值取得大一些,这样保证能够很好地区分出初始特征点与非特征点;然而对于小尺度特征应该将波动性阈值取得小一些,确保能够识别细微特征处的特征点。而波动性阈值的取值需要综合考虑这两方面的因素。

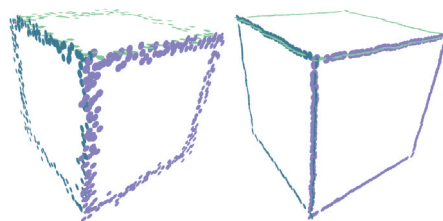
1.3 初始特征点收缩优化

由于通过设定阈值得到的初始特征点存在一定冗余数据(图3(a)),无法精准定位到特征位置,为了得到没有冗余数据并且能够准确表达特征位置的点集,本文对初始特征点进行收缩优化,提出下列优化函数

$$\min \sum_i \sum_{j \in Q_i} \|p'_i - p_j\|^2 + \| (p'_i - p_j) n_j^T \|^2 \quad (8)$$

式中 p'_i 为优化后的特征点。式(3)第1项为数据项,保证优化后的点位置与优化前尽可能相近,第2项为法向量约束项,将 p'_i 投影到由邻点 p_j 及其法线 n_j 定义的平面上。由于初始特征点靠近边缘位置,位于一个平面上的点的邻域内很容易包含位于另一平面上的点,因此,会受到另一平面上点的吸附作用,逐渐移动靠近聚集在边缘处(图3(b)),

最终形成清晰完整的特征点集。



(a) Initial feature points (b) Refined feature points

图3 收缩优化结果图

Fig.3 Feature points optimization

2 实验分析与讨论

2.1 参数选择

通过上述分析,本文的参数主要是邻域半径 r 、波动性阈值 ω 、影响因子 σ_s 、 σ_r 。对于邻域半径 r ,与模型特征尺度大小成正比,对于初始邻域半径 r 的选择以1.0%的模型包围盒对角线长度为初始值,根据具体提取效果再进行调整。影响因子 σ_s 、 σ_r 大小对结果的影响已在1.1节进行叙述,这里不再赘述。 σ_s 是距离影响因子,根据经验通常设置为和邻域大小 r 相同; σ_r 是表征邻域内点的法线相似性,一般设置为15°。对于波动性阈值 ω ,既要保证能够去除非特征点,又要保证不会去除特征点,为了生动地展示 ω 对结果的影响,实验中 ω 分别取0.005, 0.008, 0.012, 0.015和0.017,并统计了提取的特征点数量,实验结果如图4所示。从图4中可以看出, ω 越小,提取的特征点越多,却也参杂了许多非特征点; ω 越大,提取的特征点越少,但过大之后,特征点出现明显不连续,容易使特征变模糊。因此,需要根据具体模型和特征尺度大小,进行阈值的设定。确保设定的阈值能够识别模型中的细微特征。

2.2 可视化结果分析

为验证本文算法的可行性、有效性和优越性,在Intel Core i7-8700K、3.70 GHz, RAM 16 GB的PC机上,VS2013的开发平台下实现本文的多尺度特征提取方法,并引入了对比试验,实验结果如图5~7所示。图5为某机械模型的实验结果,图5(a)为其点云模型,该模型轮廓特征明显,包含各种直线与曲线特征,同时也包含尖锐与非尖锐特征,可以非常有力地验证本文算法的有效性。图5(c)基于曲率的方法和图5(d)基于法向量的方法对于变化稍小的特征不敏感,不能检测出这种小尺度特征。同时,从图5(e)不难看出,基于光顺收缩(Smooth shrink index, SSI)的方法不仅无法提取尺度较小的特征,而且会将很多非特征点误识别为特征点。从图5(f)可以看出,本文算法检测出的边界完整度高,可以清晰地识别模型的特征与基本轮廓,图6中模型具有浅特征(尺寸较小),基于法向

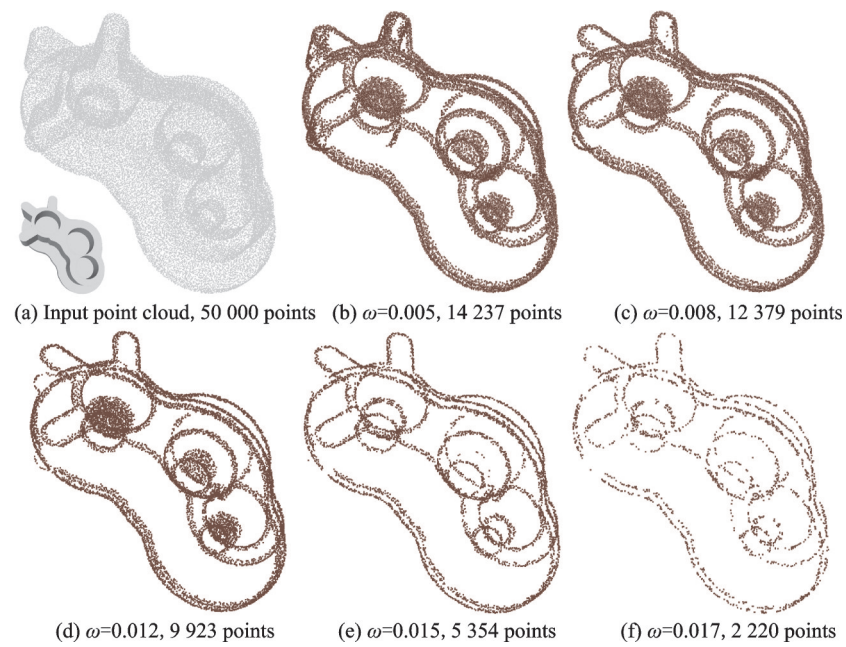


图 4 不同阈值下的特征点提取效果及特征点数统计

Fig.4 Feature extraction results and feature point statistics with different thresholds

量的方法虽然可以检测出一些小尺度特征点,但是不连续,且杂点较多,特征不清晰;对比而言,本文算法适用于各种尺度的特征,提取出的特征点清晰连续,可以较好地反映模型的结构特征。

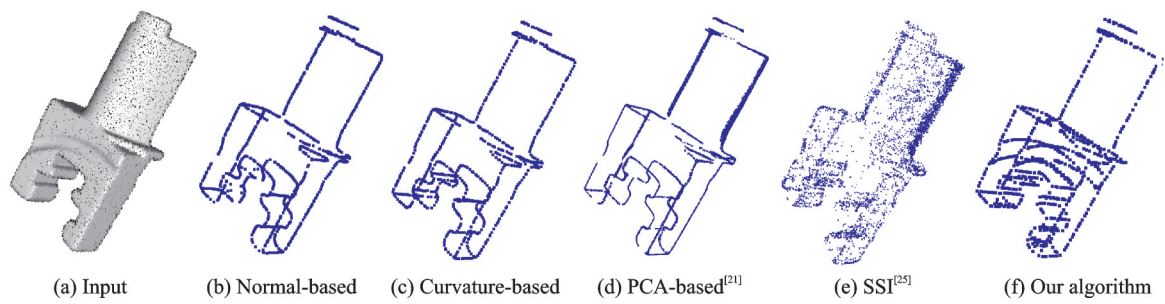


图 5 机械模型不同算法特征点提取结果

Fig.5 Feature point detection results on mechanical part by different methods

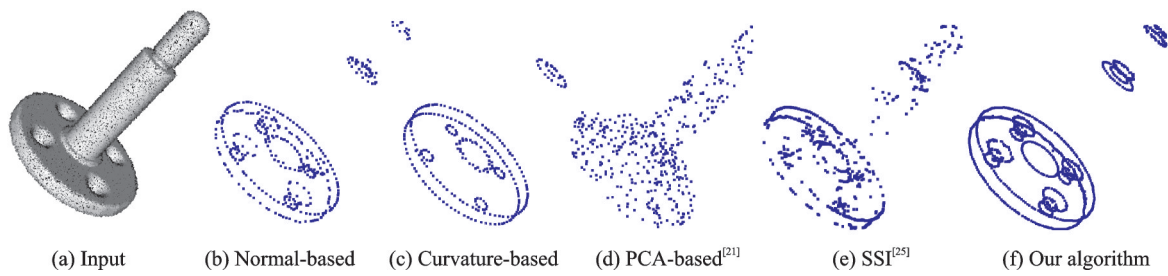


图 6 带有浅特征机械模型不同算法特征点提取结果

Fig.6 Feature point detection results on a mechanical part with shallow features by different methods

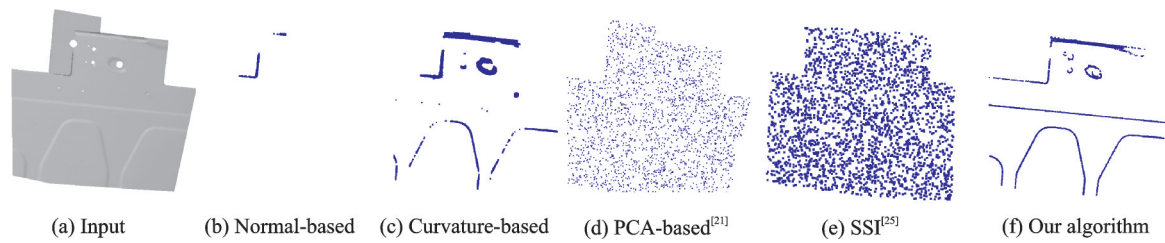


图 7 飞机蒙皮实际扫描模型不同算法特征点检测结果

Fig.7 Feature point detection results on a real-scanned aircraft skin by different methods

为了进一步验证该算法的通用性,本文加入了真实扫描数据的实验,图 7 是飞机蒙皮的原始点云模型,该模型采用 HandySCAN 700 激光扫描仪获得,扫描分辨率为 0.050 mm,扫描得到的点未经任何处理,含有实际噪声,点数为 150×10^4 ,此模型数据量较大,且蒙皮修边线相对于模型整体而言非常小,因此非常考验算法性能。从图 7(b)不难看出,基于法线的方法对于这种法线变化不明显的点云模型特征已经完全不起作用;而图 7(c)基于曲率的方法虽然能够在一定程度上检测出少量的特征点,但包含很多噪声点。从图 7(d~e)可以看出,基于协方差分析的方法和基于光顺收缩的方法无法识别点云模型中细微特征处的特征点。相比于上述方法,本文算法可以明确区分特征点与非特征点,提取出清晰准确的特征点。

2.3 定量结果分析

除了上文的定性可视化分析,本文还进行了特征点检测的量化分析。量化分析主要是对特征点检测结果进行量化的评估,包括特征点提取精度分析、算法效率分析和算法的抗噪性能分析。特征点提取精度通常定义为检测的特征点到真实特征点的平均距离。其中真实特征点是通过专业软件人工标注的结果,精度分析结果如表 1 所示。从表 1 可知,本文算法特征提取精度明显高于其余算法,首先基于邻域波动性分析的初始特征点检测方法能够无差别地检测点云模型中各种尺度的特征点,保证特征点检测的完整性;其次本文算法有收缩优化策略,能够将提取的初始特征点收缩优化到模型特征位置,因而特征点提取的精度要高于其他算法。

表 1 特征点提取误差分析

Table 1 Error statistics of feature detection mm					
图序号	法线	曲率	协方差 ^[21]	光顺收缩 ^[25]	本文算法
5	0.38	0.41	0.55	0.88	0.11
6	0.54	0.49	0.73	0.41	0.29
7	0.17	0.18	0.26	0.20	0.09

为讨论算法的时间效率,本文基于图 5~7 中的 3 个实验模型,对所有对比算法的运行时间进行了统计,如表 2 所示。由于本文算法涉及多个步骤,并且收缩优化过程存在迭代计算,算法运行的总时间与迭代次数有密切关系,故而总时间消耗多于其他方法。

为测试算法的抗噪性,本文对 3 个模型分别加入不同尺度的噪声。具体的噪声尺度是指原始模

表 2 不同算法运行效率统计分析

Table 2 Time statistics of different methods s						
图序号	点数/ 10^5	法线	曲率	协方差	光顺收缩	本文算法
5	21	0.97	1.11	1.03	4.99	5.93
6	18	0.65	1.24	0.98	4.07	4.88
7	86	7.21	8.80	9.04	11.43	10.66

型采样点相对于模型包围盒对角线长随机偏移百分比。在实验中,分别对模型施加 1%,2%,3% 的噪声。如图 8 所示,每个模型的第 1 行为噪声示意图,第 2 行是对应的特征提取结果。从图 8 中可以看出,当噪声尺度逐渐变大时,经算法处理得到的特征点集依旧较为理想。同时,计算了不同噪声下本文算法结果的误差,结果如表 3 所示。具体地,随着噪声尺度越高,算法所提取的特征点精度越低。在 1% 和 2% 的噪声尺度下,算法结果误差相差不明显,在 3% 的噪声下,算法结果明显变差。综上,本文算法抗噪性强,在处理含有噪声的模型时,可以提取出清晰准确的特征点。

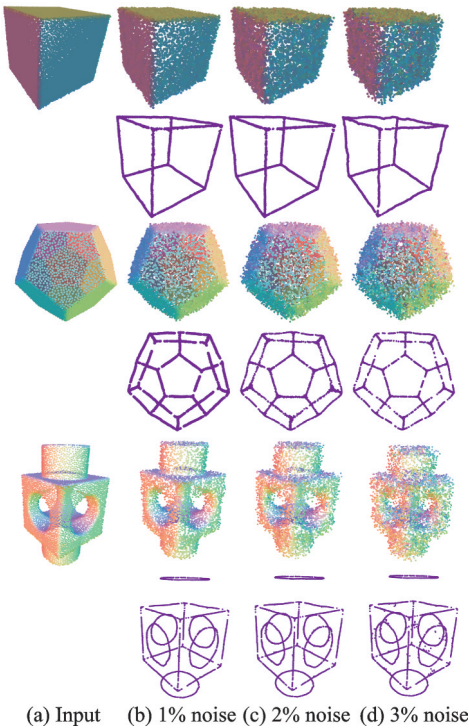


图 8 不同噪声下的特征点提取效果

Fig.8 Feature extraction results with different noise levels

表 3 不同噪声下本文算法特征检测误差分析

Table 3 Error statistics of our method with different noise level mm			
模型	1% 噪声	2% 噪声	3% 噪声
1	0.053	0.067	0.094
2	0.098	0.151	0.183
3	0.105	0.138	0.190

3 结 论

本文提出了一种针对飞机零部件散乱点云多特征的提取方法。首先,通过PCA计算、 L_1 中值滤波这一系列处理,提高点云模型质量,突出模型特征;然后,基于滤波后的法线对各点的邻域波动性进行计算,再通过统计分析整个模型的波动性分布,设置波动性阈值,得到初始特征点;最后对得到的初始特征点进行收缩优化,生成清晰完整的特征点。实验结果表明,本文方法处理过程简单有效,且没有过多的参数需要调整,特征点提取较为完整,对噪声鲁棒,对飞机零部件的数字化检测以及特征的逆向重构具有重要意义,便捷了零件原始扫描点云的处理过程,提高了点云处理质量。

尽管本文方法可以处理具有不同特征的点云模型,但是也存在需要改进的地方。对于比较复杂的模型,在两个面之间距离很小的情况下,由于该算法是对半径邻域内的点进行波动性计算的,该方法不能够很好地区别两个面并提取其中的特征,因此,这也将是下一步的研究重点。

参考文献:

- [1] 张杰. 飞机蒙皮边缘特征的提取方法研究[D]. 南京: 南京航空航天大学, 2017.
ZHANG Jie. Research on method for extracting edge feature of aircraft skin[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017.
- [2] 张沅. 基于定位工艺几何特征的机械零件数字化检测方法研究[D]. 南京: 南京航空航天大学, 2017.
ZHANG Yuan. Digital inspection of mechanical parts based on positioning process features [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017.
- [3] 史建华, 刘盼. 大尺寸航空发动机叶片的高效型面检测方法[J]. 计量学报, 2018, 39(5): 605-608.
SHI Jianhua, LIU pan. High efficiency profile detection method for large size aero engine blades[J]. Journal of Metrology, 2018, 39(5): 605-608.
- [4] 孙钰科. 三维激光点云数据的处理及应用研究[D]. 上海: 上海师范大学, 2018.
SUN Yuke. Research on 3D laser point cloud process and application [D]. Shanghai: Shanghai Normal University, 2018.
- [5] 薛珊, 吕南方, 沈雨鹰, 等. 基于激光三维点云的机械工件识别方法[J]. 红外与激光工程, 2019, 48(4): 169-176.
XUE Shan, LYU Nanfang, SHEN Yuying, et al. Mechanical workpiece recognition method based on laser three dimensional point cloud[J]. Infrared and Laser Engineering, 2019, 48(4): 169-176.
- [6] 高如玉. 基于双目视觉的三维重建软件设计[D]. 沈阳: 沈阳工业大学, 2018.
GAO Ruyu. Design of 3D reconstruction software based on binocular vision [D]. Shenyang: Shenyang University of Technology, 2018.
- [7] 任前程. 一种点云特征线提取方法[J]. 激光与光电子学进展, 2019, 56(6): 229-235.
REN Qiancheng. Method for extracting feature lines of point cloud[J]. Progress in Laser and Optoelectronics, 2019, 56(6): 229-235.
- [8] 胡佳贝, 刘喆, 张鹏飞, 等. 基于离散Morse理论的散乱点云特征提取[J]. 光学学报, 2019, 39(6): 232-241.
HU Jiabei, LIU Zhe, ZHANG Pengfei, et al. Feature extraction of scattered point clouds based on discrete Morse theory [J]. Acta Optica Sinica, 2019, 39(6): 232-241.
- [9] 钱锦锋, 陈志杨, 张三元, 等. 点云数据压缩中的边界特征检测[J]. 中国图象图形学报, 2005, 10(2): 164-169.
QIAN Jinfeng, CHEN Zhiyang, ZHANG Sanyuan, et al. Boundary feature detection in point cloud data compression[J]. Chinese Journal of Image and Graphics, 2005, 10(2): 164-169.
- [10] 陈朋, 谭晔汶, 李亮. 地面三维激光扫描建筑物点云特征线提取[J]. 激光杂志, 2016, 37(3): 9-11.
CHEN Peng, TAN Yewen, LI Liang. Feature line extraction of point clouds of buildings based on 3D ground laser scanning [J]. Laser Magazine, 2016, 37(3): 9-11.
- [11] DANIELS J, HA L K, OCHOTTA T, et al. Robust smooth feature extraction from point clouds[C]//Proceedings of IEEE Computer Society. [S.l.]: IEEE, 2007: 123-136.
- [12] HO H T, GIBBINS D. Curvature-based approach for multi-scale feature extraction from 3D meshes and unstructured point clouds[J]. IET Computer Vision, 2009, 3(4): 201-212.
- [13] JINHU W, RODERIK L, YUEQIAN S. Coarse point cloud registration by Egi matching of voxel clusters[J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 3(12): 98-99.
- [14] DEMARSIN K, VANDERSTRAETEN D, VOLODI-NE T, et al. Detection of closed sharp edges in point clouds using normal estimation and graph theory [J]. Computer Aided Design, 2007, 39(4): 276-283.
- [15] 史皓良, 吴禄慎, 余喆琦, 等. 散乱点云数据特征信息提取算法[J]. 计算机工程, 2017, 43(8): 279-283.
SHI Haoliang, WU Lushen, YU Zheqi, et al. Algo-

- rithm for extracting feature information of scattered point cloud data[J]. Computer Engineering, 2017, 43(8): 279-283.
- [16] 邹万红, 陈志杨, 叶修梓, 等. 一种新的点云数据特征骨架提取方法[J]. 浙江大学学报(工学版), 2008, 42(12): 2103-2107.
- ZOU Wanhong, CHEN Zhiyang, YE Xiuzi, et al. A new method for feature skeleton extraction of point cloud data[J]. Journal of Zhejiang University (Engineering Edition), 2008, 42(12): 2103-2107.
- [17] LIU X S, JIN C N. Feature line extraction from unorganized noisy point clouds[J]. Journal of Computational Information Systems, 2014, 10(8): 3503-3510.
- [18] KIM S K. Extraction of ridge and valley lines from unorganized points[J]. Multimedia Tools and Applications, 2013, 63(1): 265-279.
- [19] GUMHOLD S, WANG X, MACLEOD R. Feature extraction from point clouds [C]//Proceedings of 10th International Meshing Roundtable. Sandia : Sandia National Laboratories, 2001: 293-305.
- [20] 上官宁, 刘斌. 三角网格模型特征线提取方法[J]. 华侨大学学报(自然版), 2010, 31(5): 487-490.
- SHANG Guanning, LIU Bing. Triangular grid model feature line extraction method[J]. Journal of Huaqiao University (Natural Edition), 2010, 31(5): 487-490.
- [21] PAULY M, KEISER R, GROSS M. Multi-scale feature extraction on point-sampled surfaces[J]. Computer Graphics Forum, 2003, 22(3): 281-89.
- [22] 庞旭芳, 庞明勇, 肖春霞, 等. 点云模型谷脊特征的提取与增强算法[J]. 自动化学报, 2010, 36(8): 1073-1083.
- PANG Xufang, PANG Mingyong, XIAO Chunxia, et al. Algorithm for extracting and enhancing valley ridge features of point cloud model[J]. Journal of Automation, 2010, 36(8): 1073-1083.
- [23] WEBER C, HAHMANN S, HAGEN H. Sharp feature detection in point clouds [C]//Proceedings of IEEE International Conference on Shape Modeling and Applications. [S.l.]: IEEE, 2010: 175-186.
- [24] HOPPE H, DEROSE T, DUCHAMP T, et al. Surface reconstruction from unorganized points[J]. ACM SIGGRAPH Computer Graphics, 1992, 26(2): 71-78.
- [25] NIE J. Extracting feature lines from point clouds based on smooth shrink and iterative thinning[J]. Graphical Models, 2016, 84: 38-49.

(编辑:陈珺)