

基于法向量和曲率估计的点云数据预处理研究

叶宇翔, 付尧明

中国民用航空飞行学院 航空工程学院, 四川 广汉 618307

DOI: 10.61369/TACS.2026060044

摘 要 : 针对复杂点云在三维扫描与模型采样过程中存在的噪声干扰、点密度不均、局部几何属性缺失等问题, 提出一种以法向量估计和曲率计算为核心, 并结合统计滤波去噪、体素网格下采样的点云预处理流程。研究表明, 该预处理流程能够改善点云输入质量, 提高局部几何特征的一致性, 为后续复杂零件点云深度学习特征提取、鲁棒匹配和高精度配准提供稳定的数据基础。

关 键 词 : 三维点云; 法向量估计; 曲率估计

Research on Point Cloud Data Preprocessing Based on Normal Vectors and Curvature Estimation

Ye Yuxiang, Fu Yaoming

Civil Aviation Flight University of China College of Aeronautical Engineering, Guanghan, Sichuan 618307

Abstract : Addressing issues such as noise interference, uneven point density, and missing local geometric properties in complex point clouds during 3D scanning and model sampling, a point cloud preprocessing workflow is proposed. This workflow centers around normal vector estimation and curvature calculation, and incorporates statistical filtering for denoising and downsampling within a voxel grid. Research indicates that this preprocessing workflow enhances the quality of point cloud input, improves the consistency of local geometric features, and lays a stable data foundation for subsequent deep learning feature extraction, robust matching, and high-precision registration of complex part point clouds.

Keywords : 3D point cloud; normal vector estimation; curvature estimation

引言

点云是依托离散采样点记录三维物体表面几何特征的数据集合, 该类数据普遍具备无序性、非结构化以及空间分布疏密不均的特性。随着三维扫描、逆向工程、智能加工等技术的持续迭代升级, 点云数据现已广泛应用于精密零部件质量检测、三维模型重构、点云匹配对齐以及加工误差分析等工业场景。对于结构形态复杂的工业零部件, 实测采集的点云虽可完整留存丰富的局部几何细节, 但数据品质易受传感设备分辨率、物体遮挡程度、采样拍摄角度等外界条件干扰, 极易产生噪声点、离群异常点以及局部数据缺失等缺陷。上述问题会降低点云对物体真实外形的还原精度, 同时会干扰后续特征提取、配准运算的稳定性^[1-2]。

近年来, 深度学习技术在点云处理、点云配准领域实现快速迭代, Transformer 架构与注意力机制也逐步应用于点云特征表征、匹配关联建模等研究方向, 以此强化模型对点云空间几何信息的提取与表达能力^[3]。但深度学习模型的综合性能并非仅由网络架构决定, 输入样本的数据品质同样起到基础性作用。若原始点云包含大量异常点位, 或是局部几何特征波动较大, 模型训练阶段极易将噪声误判为有效特征进行学习, 从而降低特征辨识度。尤其在点云配准任务中, 法向量、曲率、局部邻域拓扑结构直接决定匹配点筛选效果与刚体变换矩阵的求解精度, 因此, 在将点云导入深度学习模型前, 构建一套稳定性强的预处理流程具有重要研究意义。

常规的传统点云预处理手段主要包含去噪、下采样两大核心步骤^[4]。其中, 去噪操作能够削弱异常数据对点云局部结构的干扰, 下采样则可精简数据体量、降低运算成本, 同时优化点云空间分布均匀度。基于以上背景, 本文以复杂工业点云为研究样本, 围绕法向量与曲率参数估算优化点云预处理算法, 整合处理步骤并搭建适配深度学习模型输入的标准化预处理流程。

一、预处理流程

本文构建的点云预处理流程主要由以下环节组成, 如图1所示: 一是采用统计滤波去除离群点和明显异常点; 二是采用体素

网格方法降低点云冗余度; 三是建立局部邻域并计算协方差矩阵; 四是由协方差矩阵特征分解获得法向量, 并利用特征值比例计算曲率。整个流程兼顾数据质量、几何属性表达和网络输入一致性, 非常适合用于模型点云与实际扫描点云的统一预处理。




图1 点云数据预处理流程图

二、点云去噪与下采样

复杂零件点云中的噪声主要表现为随机扰动和离群点两类。随机扰动多出现在表面附近，会使局部曲面呈现不够平滑的状态；离群点通常偏离主体结构较远，对邻域估计和配准误差函数容易产生干扰。对于法向量和曲率计算来说，邻域点的统计分布直接影响计算结果，一旦邻域内混入异常点，协方差矩阵的特征值和特征向量就可能出现偏移，进而造成法向量方向偏差和曲率值失真。因此，在计算几何属性之前进行去噪处理，是保证后续结果稳定性的必要环节^[5]。

统计滤波方法主要依据点云局部邻域内距离分布的统计规律，通过分析点与邻域点之间的距离关系来判断离群点。设点云为 $P = \{p_i\}$ ，对于任意一点 p_i ，选取其 k 近邻点集合 N_i ，则该点到邻域点的平均距离可表示为：

$$d_i = \frac{1}{k} \sum_{j=1}^k \|p_i - p_j\|$$

式中： d_i 表示点 p_i 到其邻域点的平均距离， k 表示邻域点的数量， p_j 表示邻域中的第 j 个点， $\|\cdot\|$ 表示欧几里得范数，当 d_i 较大时，说明该点远离其邻域，可能为离群点。

$$|d_i - \mu| > \alpha \sigma$$

式中： α 为经验系数，一般取值在 1.0~3.0 之间。当某点的平均距离偏离整体均值超过 α 倍标准差时，可认为该点不符合局部密度分布特性，从而被判定为离群点。

下采样的目标是在减少点数的同时尽可能保持点云整体轮廓和局部几何结构，实际扫描点云往往会包含大量冗余点，直接输入深度学习网络会增加计算量和显存占用，也会降低法向量和曲率计算效率。常见点云下采样方法为体素网格下采样^[6]。

体素网格下采样方法通过将三维空间划分为规则网格，并用每个网格中的代表点替代原始点集，从而实现点云压缩。在该方法中，将空间划分为边长为 l 的立方体网格，每个网格称为一个体素。对于任意点 $p_i = (x_i, y_i, z_i)$ ，其所属体素索引可表示为：

$$v_i = \left\lfloor \left\lfloor \frac{x_i}{l} \right\rfloor, \left\lfloor \frac{y_i}{l} \right\rfloor, \left\lfloor \frac{z_i}{l} \right\rfloor \right\rfloor$$

式中： v_i 表示点所在体素的索引， l 表示体素边长，下括号表示向下取整运算。该公式的作用是将连续空间坐标映射到离散网格索引，从而实现空间划分。

三、法向量和曲率估计

法向量是描述点云局部表面方向的重要几何属性。本文采用

基于主成分分析的方法进行估计^[7]。设点云为 $P = \{p_i\}$ ，对于任意点 p_i ，选取其邻域点集合 N_i ，邻域点数为 k ，则邻域质心可表示为：

$$\bar{p}_i = \frac{1}{k} \sum_{j=1}^k p_j$$

式中， $\bar{p}_i$ 表示点 p_i 邻域的质心， p_j 表示邻域中的第 j 个点。并构建邻域点的协方差矩阵：

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

式中， C_i 表示点 p_i 邻域对应的协方差矩阵， T 表示转置运算。该矩阵能够反映邻域点在不同方向上的空间分布特征^[8]。对协方差矩阵进行特征值分解：

$$C_i v_m = \lambda_m v_m, m=1, 2, 3$$

式中， λ_m 表示第 m 个特征值， v_m 表示对应的特征向量。将特征值按降序排列为 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ ，则最小特征值对应的特征向量可作为该点的法向量：

$$n_i = v_3$$

式中， n_i 表示点 p_i 的法向量。由于最小特征值对应的方向是邻域点变化最小的方向，因此该方向可近似表示局部曲面的法线方向^[9]。

在法向量估计的基础上，可进一步利用协方差矩阵特征值计算局部曲率，以表征点云表面的弯曲程度。曲率通常定义为最小特征值在总特征值中的占比：

$$\kappa_i = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}$$

式中， κ_i 表示点 p_i 的曲率， λ_1 、 λ_2 、 λ_3 为邻域协方差矩阵的三个特征值，且满足 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ 。

当点云处于平坦区域时，邻域点主要分布在局部平面内， λ_3 较小，因此曲率值较低；当点位于边缘、尖角或曲面变化剧烈区域时，邻域点在法向方向上的离散程度增大， λ_3 相对增大，曲率值随之升高^[10]。

为直观分析曲率估计结果，将每个点计算得到的曲率值归一化后映射为彩色热图，如图1左侧点云所示。其中，低曲率区域以蓝色表示，通常对应于较为平坦的表面；高曲率区域以红色表示，通常分布在边缘、尖角以及局部几何变化剧烈的位置。为直观分析法向量估计结果，将每个点计算得到的法向量以线段形式显示在点云表面。如图2右侧点云所示，在较为平坦的区域，法向量方向分布较为一致；而在边缘、尖角以及曲面弯曲较明显的位置，法向量方向变化相对剧烈，表明这些区域具有更加复杂的局部几何特征。




图2 曲率与法向量估计结果可视化

四、结论

针对复杂点云在配准作业中存在的点云数据质量缺陷,本文提出一套结合法向量与曲率估算的点云预处理优化方案。试验结果证明,统计滤波算法能够有效抑制离群异常点对点云邻域拓扑结构的破坏;体素下采样可在精简点云数量、压缩数据体量的同时,

保证良好的空间分布特性;依托协方差矩阵完成法向量求解与曲率测算,能够进一步优化点云局部几何特征的表征能力。该预处理方案同时适配模型生成点云与实景扫描点云,可为后续特征提取、稳健匹配、几何约束优化以及刚体配准求解提供高质量的数据支撑。

参考文献

[1] ZHANG Y X, GUI J, YU B, CONG X F, GONG X, TAO W B, TAO D. A comprehensive survey and taxonomy on point cloud registration based on deep learning[C]//Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence. Jeju: IJCAI, 2024: 8344-8352.

[2] CHEN L, FENG C Z, MA Y P, ZHAO Y K, WANG C R. A review of rigid point cloud registration based on deep learning[J]. Frontiers in Neurorobotics, 2024, 17: 1281332.

[3] HUANG S Y, GOJCIC Z, USVYATSOV M, WIESER A, SCHINDLER K. PREDATOR: registration of 3D point clouds with low overlap[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 4267-4276.

[4] YEW Z J, LEE G H. REGTR: end-to-end point cloud correspondences with transformers[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 6667-6676.

[5] LI D W, WEI Y C, ZHU R S. A comparative study on point cloud down-sampling strategies for deep learning-based crop organ segmentation[J]. Plant Methods, 2023, 19: 124.

[6] LANG I, MANOR A, AVIDAN S. SampleNet: differentiable point cloud sampling[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 7578-7588.

[7] LUO S T, HU W. Score-based point cloud denoising[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 4583-4592.

[8] MAO A H, DU Z H, WEN Y H, XUAN J, LIU Y J. PD-Flow: a point cloud denoising framework with normalizing flows[C]//European Conference on Computer Vision. Cham: Springer, 2022.

[9] ZHU R S, LIU Y, DONG Z, JIANG T P, WANG Y, WANG W P, YANG B S. AdaFit: rethinking learning-based normal estimation on point clouds[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 6118-6127.

[10] XIU H Y, LIU X, WANG W M, KIM K S, MATSUOKA M. MSECNet: accurate and robust normal estimation for 3D point clouds by multi-scale edge conditioning[C]//Proceedings of the 31st ACM International Conference on Multimedia. New York: ACM, 2023: 2535-2543.