

8-15-2024

Section Point Cloud Denoising Method Based on Enhanced DBSCAN and Distance Consensus Evaluation

Chengpeng Ge

School of Naval Architecture & Ocean Engineering, Jiangsu University of Science & Technology, Zhenjiang 212003, China

Dong Zhao

School of Naval Architecture & Ocean Engineering, Jiangsu University of Science & Technology, Zhenjiang 212003, China

Rui Wang

School of Naval Architecture & Ocean Engineering, Jiangsu University of Science & Technology, Zhenjiang 212003, China

Qinghua Ma

Jiangsu Hantong Wing Heavy Industry Co, Nantong 226010, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Special Column: Digital Twin and Intelligent Simulation of Marine and Maritime is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Section Point Cloud Denoising Method Based on Enhanced DBSCAN and Distance Consensus Evaluation

Abstract

Abstract: A denoising method based on the improved DBSCAN(density-based spatial clustering of applications with noise) algorithm is proposed to address the problem of removing noise points in point cloud data. The statistical filtering method is applied to pre-screen isolated outliers and remove largescale noise from the point cloud. The DBSCAN algorithm is optimized to reduce computational time complexity and achieve adaptive parameter adjustment, thereby dividing the point cloud into normal clusters, suspected clusters and abnormal clusters, and immediately removing abnormal clusters. Distance consensus assessment is applied, and suspect clusters are further evaluated. By calculating the distance between the suspected point and its nearest normal point fitting surface, it is determined whether the suspected point is abnormal, effectively maintaining the key features of the data and model sensitivity. This approach outperforms other algorithms in denoising efficiency and feature retention by being implemented on hull point clouds, which ensures the integrity of the point cloud data's geometric properties.

Keywords

point cloud denoising, point cloud data, DBSCAN(density-based spatial clustering of applications with noise) clustering, distance consensus assessment, feature preservation

Recommended Citation

Ge Chengpeng, Zhao Dong, Wang Rui, et al. Section Point Cloud Denoising Method Based on Enhanced DBSCAN and Distance Consensus Evaluation[J]. Journal of System Simulation, 2024, 36(8): 1800-1809.

基于改进DBSCAN和距离共识评估的分段点云去噪方法

葛程鹏¹, 赵东^{1*}, 王蕊¹, 马庆华²

(1. 江苏科技大学 船舶与海洋工程学院, 江苏 镇江 212003; 2. 江苏韩通赢吉重工有限公司, 江苏 南通 226010)

摘要: 针对点云数据中噪声点的剔除问题, 提出了一种基于改进DBSCAN(density-based spatial clustering of applications with noise)算法的多尺度点云去噪方法。应用统计滤波对孤立离群点进行预筛选, 去除点云中的大尺度噪声; 对DBSCAN算法进行优化, 减少算法时间复杂度和实现参数的自适应调整, 以此将点云分为正常簇、疑似簇及异常簇, 并立即去除异常簇; 利用距离共识评估法对疑似簇进行精细判定, 通过计算疑似点与其最近的正常点拟合表面之间的距离, 判定其是否为异常, 有效保持了数据的关键特征和模型敏感度。利用该方法对两个船体分段点云进行去噪, 并与其他去噪算法进行对比, 结果表明, 该方法在去噪效率和特征保持方面具有优势, 精确地保留了点云数据的几何特性。

关键词: 点云去噪; 点云数据; DBSCAN(density-based spatial clustering of applications with noise) 聚类; 距离共识评估; 特征保持

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2024)08-1800-10

DOI: 10.16182/j.issn1004731x.joss.24-0153

引用格式: 葛程鹏, 赵东, 王蕊, 等. 基于改进DBSCAN和距离共识评估的分段点云去噪方法[J]. 系统仿真学报, 2024, 36(8): 1800-1809.

Reference format: Ge Chengpeng, Zhao Dong, Wang Rui, et al. Section Point Cloud Denoising Method Based on Enhanced DBSCAN and Distance Consensus Evaluation[J]. Journal of System Simulation, 2024, 36(8): 1800-1809.

Section Point Cloud Denoising Method Based on Enhanced DBSCAN and Distance Consensus Evaluation

Ge Chengpeng¹, Zhao Dong^{1*}, Wang Rui¹, Ma Qinghua²

(1. School of Naval Architecture & Ocean Engineering, Jiangsu University of Science & Technology, Zhenjiang 212003, China;

2. Jiangsu Hantong Wing Heavy Industry Co, Nantong 226010, China)

Abstract: A denoising method based on the improved DBSCAN(density-based spatial clustering of applications with noise) algorithm is proposed to address the problem of removing noise points in point cloud data. The statistical filtering method is applied to pre-screen isolated outliers and remove large-scale noise from the point cloud. The DBSCAN algorithm is optimized to reduce computational time complexity and achieve adaptive parameter adjustment, thereby dividing the point cloud into normal clusters, suspected clusters and abnormal clusters, and immediately removing abnormal clusters. Distance consensus assessment is applied, and suspect clusters are further evaluated. By calculating the distance between the suspected point and its nearest normal point fitting surface, it is determined whether the suspected point is abnormal, effectively maintaining the key features of the data and model sensitivity. This approach outperforms other algorithms in denoising efficiency and feature retention by

收稿日期: 2024-02-23 修回日期: 2024-05-05

基金项目: 江苏省研究生科研与实践创新计划项目(SJCX23_2205); 2023江苏省工业和信息产业转型升级项目(苏财工贸(2023)60号)

第一作者: 葛程鹏(1998-), 男, 硕士生, 研究方向为船舶先进制造技术。

通讯作者: 赵东(1967-), 男, 副教授, 硕士, 研究方向为船舶先进制造技术、数字化制造。

being implemented on hull point clouds, which ensures the integrity of the point cloud data's geometric properties.

Keywords: point cloud denoising; point cloud data; DBSCAN(density-based spatial clustering of applications with noise) clustering; distance consensus assessment; feature preservation

0 引言

三维激光扫描技术突破了传统的单点测量方法,能快速获取被测对象表面的三维点云数据,快速提供被测对象的三维模型及加工精度等信息,在船舶设计制造领域受到越来越多的关注。在船舶设计初期阶段,可以三维激光扫描获取母型船舶数据以便快速开展新船设计;在建造过程中,通过三维激光扫描掌握各个构件的精度数据,大大提高了完工船舶的精度与质量^[1-3]。然而,点云数据的处理面临诸多挑战,尤其是数据噪声问题,其影响到点云数据的质量和可用性。因此,研究高效、准确的点云去噪算法、优化点云处理流程是设计制造领域亟待解决的问题。

近年来,点云去噪一直是国内外学者高度关注的研究领域,Sun等^[4]通过加权 L_0 范数最小化点来实现各向异性点云去噪,在有效保持尖锐区域特征的同时平滑剩余区域,但在尖锐特征附近存在局部间隙。Mattei等^[5]提出的移动主成分分析(mobile robust principal component analysis, MRPCA)去噪算法有效结合了局部和全局结构,通过加权 L_1 最小化保留尖锐特征,但在处理高噪声点云时运行时间较长。卢钰仁等^[6]结合空间单元格划分和双边滤波以及法向修正,有效去除离群点并保持了点云模型的几何特征,然而在处理大规模噪声点时,算法的计算效率和去噪彻底性有待提高。范晨等^[7]通过空间栅格划分和改进双边滤波算法在保持装配面特征的同时有效去除了噪声,避免了传统双边滤波去噪后的过度光滑现象。Hu等^[8]通过调整局部密度排斥项和引入各向异性权重函数改进了各向异性加权最小二乘法(anisotropic weighted least squares method, AWLOP),实现更均匀的输出并更好地保留尖锐特征,但在高噪声水

平下容易发生过度平滑和锐化。郭进等^[9]通过高斯参数 σ_c 和 σ_s 控制光滑程度和特征保持程度,有效实现了点云中小尺度噪声点的各向异性去噪,同时较好地保留了点云特征。Zeng等^[10]提出了一种基于低维流形模型(low dimensional manifold model, LDMM)的三维点云去噪方法,利用点云表面的自相似特性,通过对相似表面块同时进行去噪处理来更好地保留尖锐特征以及边缘等视觉上的结构特征,但特征选择计算过程相对耗时。Muhammad等^[11]通过构建基于几何和颜色的k-最近邻图,并利用凸优化方法进行点云的颜色去噪,模拟结果显示,该算法获得了较好的质量指标。徐志博等^[12]通过结合离群因子和K-means++聚类改进的方法对点云进行去噪,有效识别并去除了大部分明显离散的噪声点和孤立噪声簇,但该算法在去除与主体点云密度接近的孤立噪声簇的识别和去除效果有限。戴士杰等^[13]通过迭代滤波修正和位置滤波参数的自适应调整,有效实现了对不同尺度噪声的去噪处理并保持了高频尖锐区和低频平坦区的特征,然而这种方法在处理与采样点几何特征密切相关的噪声时存在局限性。

本文提出了一种多尺度的点云去噪方法,通过对点云中的噪声进行细致的尺度和区域划分,有效识别并去除含有混合噪声的点云数据,从而实现更高效和精确的去噪效果。

1 基于统计滤波的大尺度噪声去除

三维点云数据除了无序性和非结构化特点外,还存在大尺度噪声。这些噪声通常来源于扫描设备的误差、环境因素或其他非目标物体干扰,与主体数据有明显偏差的孤立点或点群,显著影响数据的质量和后续处理的准确性。目前,统计滤

波被广泛应用于识别和去除大尺度噪声，以优化点云数据质量，提升后续处理和分析精度。

统计滤波通过计算每个点与其邻近点的距离统计量来评估噪声。确定每个点与其邻域内所有点的平均距离：

$$\bar{d}(p) = \frac{1}{k} \sum_{i=1}^k \|p - q_i\| \quad (1)$$

式中： $\bar{d}(p)$ 为点 p 与其 k 个最近邻点 q_i 的平均距离； i 为点的编号； $\|p - q_i\|$ 为点 p 与点 q_i 之间的欧式距离。

假设这些距离为服从高斯分布，即 $\mathcal{N}(\mu, \delta^2)$ ，其中， μ 是均值， δ 是标准差。基于这一假设，可以设定一个阈值来识别并排除噪声点。如果某个数据点与其邻近点的平均距离超出 $\mu + \delta$ ，则该点被视为噪声点。

2 基于改进DBSCAN的小尺度噪声去除

2.1 DBSCAN 聚类算法原理

DBSCAN(density-based spatial clustering of applications with noise)是一种基于密度的空间聚类算法，能有效地处理噪声数据集并识别出多种形状的聚类簇。该算法基于以下概念：

MinPts: 定义核心点所需的最少数据点数。

ϵ 邻域: 对于数据集中的点 p ，其半径 ϵ 内的区域称为点 p 的 ϵ 邻域。

直接密度可达: 若 p 在 q 的 ϵ 邻域内，且 q 的 ϵ 邻域中至少有最小点数MinPts，则点 p 对点 q 直接密度可达。

密度可达: 在数据集 D 中，如果存在一系列点 p_1, p_2, \dots, p_n ，其中每个点 p_i 从 p_{i-1} 直接密度可达($i \geq 2$)，则 p_n 从 p_1 密度可达。

DBSCAN算法的核心过程可以用以下步骤来描述。

step 1: 对数据集 D 中每个点的 ϵ 邻域进行计算，判断是否为核心点；

step 2: 从核心点出发，通过直接密度可达关系，找出所有密度可达的点，形成簇；

step 3: 非核心点且不直接密度可达的点标记为噪声点。

DBSCAN的优点在于不需指定簇数量，能有效处理噪声和复杂形状簇，算法性能依赖于 ϵ 和MinPts参数，其选择需基于数据集特性。DBSCAN聚类原理如图1所示。




图1 DBSCAN 聚类原理

Fig. 1 Principles of DBSCAN clustering

2.2 DBSCAN 算法改进

2.2.1 时间复杂度改进

传统DBSCAN聚类算法采用穷举搜索进行数据的划分，其时间复杂度为 $O(n^2)$ ，主要来自于计算距离矩阵的 $O(n^2)$ 时间复杂度以及对每个点进行邻域查询的 $O(n \cdot k)$ 时间复杂度，其中 k 代表数据点的平均密度。使用kd-tree优化DBSCAN算法，计算距离矩阵的 $O(n^2)$ 的空间复杂度可降至 $O(n \cdot k)$ 的空间复杂度，邻域查询时间复杂度可降低到 $O(n \cdot \log n + k \log n^2)^{[4]}$ ，这是因为kd-tree允许在 $\log n$ 时间内完成点查询，并能有效进行范围搜索。

kd-tree优化DBSCAN算法步骤如下。

step 1: 构建kd-tree，将数据点插入kd-tree，构建过程时间复杂度为 $O(n \cdot \log n)$ ；

step 2: 邻域查询优化，使用kd-tree进行邻域

查询, 每次查询的时间复杂度降低到 $O(\text{lb } n)$;

step 3: 更新时间复杂度, 综合构建和查询步骤, 改进后 DBSCAN 算法的总时间复杂度为 $O(n \cdot \text{lb } n + kn \cdot \text{lb } n)$ 。

为验证 kd-tree 索引结构对聚类的加速效果, 分别对传统 DBSCAN 聚类、距离矩阵预计算优化 DBSCAN 及 kd-tree 优化后的 DBSCAN 聚类算法的用时进行对比, 测试机器 CPU 为 AMD 5600H, 3 种 DBSCAN 算法的聚类效果均相同, 结果如图 2 所示。基于不同方法加速的 DBSCAN 算法聚类耗时对比如表 1 所示, 从表 1 中数据可以看出, 预先计算距离矩阵的优化可以加速 1 倍, 使用 kd-tree 优化可以加速约 80 倍。

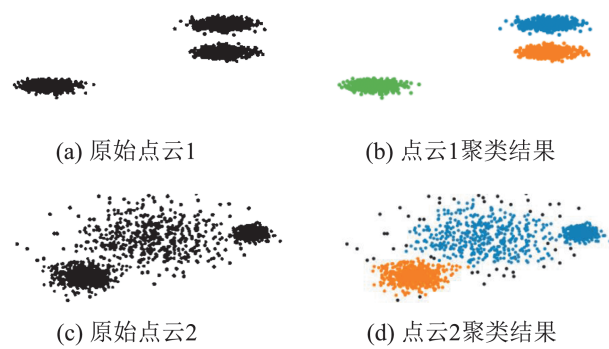


图2 DBSCAN 聚类结果

Fig. 2 Results of DBSCAN clustering

表1 各算法运行用时对比

Table 1 Comparison of each algorithm runtime

点云	点云算法	运行用时/s
1	DBSCAN simple	9.838
	DBSCAN pre-compute	5.125
	DBSCAN kd-tree	0.138
2	DBSCAN simple	12.402
	DBSCAN pre-compute	6.043
	DBSCAN kd-tree	0.151

2.2.2 参数自适应选取

在 DBSCAN 算法中, 点核心对象数 MinPts 和邻域半径 ϵ 的选取会极大影响聚类的效果。为了优化去噪效果并减少人工参数调整, 本文引入统计学中的拐点^[15]概念, 提出一种依据数据分布特性

自适应确定邻域半径的方法。拐点是指在一组数据序列中, 数据变化率发生显著变化的点。本文用拐点来标示数据点在正常点和噪声点之间的分界。

针对给定数据集 D 中的每个样本点 p_i , 计算其与第 N 近邻的欧式距离。该计算遵循传统的欧式距离公式:

$$\text{dist}(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (2)$$

式中: (x_i, y_i, z_i) 和 (x_j, y_j, z_j) 分别为样本点在空间中的坐标。

将所有的距离值 $d(k, p_i)$ 进行升序排序, 以构建一个表征样本间距离关系的分布图, 如图 3 所示。三维激光扫描获取的目标点云数据通常距离较均匀, 而噪声点云数据则相对分散。因此, 噪声点云与正常点云之间的距离关系在分布图中会显示出明显的突变, 即图 3 中所示的拐点。




图3 点云距离关系分布图

Fig. 3 Distribution map of point cloud distance relationships

计算图中任意 3 个连续点形成的 2 个向量间角度的余弦值角度的余弦值, 其中余弦值最小的点即为拐点 d_{elbow} , 标志着曲线在此处的弯曲程度达到最大。

将此拐点对应的距离值定为邻域半径 ϵ , 同时将该点对应的 N 值确定为最小核心点数 MinPts。通过此方法, 可以在减少人工干预的同时, 有效提高密度聚类算法的去噪效果。

2.3 基于距离共识评估算法的DBSCAN小尺度噪声点去除算法

2.3.1 距离共识评估算法

距离共识评估(distance consensus assessment, DCA)是一种集体决策方法,相较于个体评估,它具备更高的可靠性。假定所有评估者具备合理判断能力,并能作出正确的决定,该方法通过比较疑似簇中每一个点与其最近的评估者之间的距离来共同判断是否为异常点。这一过程中,每个疑似点的评估依据由其最近 M 个正常点通过计算与疑似点之间距离来完成。如果大多数评估指向异常,则该点被认定为异常。距离共识评估机制能有效避免因邻近点误判而将异常点错误归类为正常,保证即使部分评估者判断失误,整体评估结果依然可信。

具体距离计算采用PCA进行二次曲面拟合。通过PCA提取数据共方差矩阵的特征向量,以此建立数据主轴。将数据集中并计算其共方差矩阵:

$$C = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T \quad (3)$$

求解特征值问题 $Cv = \lambda v$,其中 v 是特征向量, λ 是对应的特征值。通过对特征值大小进行排序,确定数据方差最大方向,即第一主成分,其次是第二大特征值对应方向,以此类推。点与二次曲面拟合模型的距离为

$$f(x) = x^T Ax + b^T x + c \quad (4)$$

式中: A 为对称矩阵; b 为偏移向量; c 为常数项; x 为数据点在新坐标轴上的投影。

利用PCA降维后的数据求解最优拟合曲面的参数,以此计算点与表面间距,并据此通过判断该距离是否小于设定的阈值来进行评估决定点是否异常。通常情况下,正常点倾向于遵循表面的几何形状,而 σ_r 代表点间距离的标准差。若点间距离小于 $x\sigma_r + \bar{x}$,则该点被视为正常点;反之,则将其评估为异常点。进一步为每个疑似点选定 M 个最邻近正常点作为评估者,如果超过半数评估

者判定该点为异常,则最终将该点判定为异常,最后剔除所有判定为异常的点。

2.3.2 基于DCA和DBSCAN进行点云去噪

结合DBSCAN算法和DCA算法,建立两阶段异常点检测方法。

首先,利用DBSCAN算法完成数据点初步分类,将点云区域内的核心点划分为正常簇,与核心点相邻的密度可达点分类为疑似簇,既非核心点也非密度可达点的数据则被标记为异常簇,并立即移除。其次,通过DCA算法,将正常簇中的核心点用于评估疑似簇的点。通过计算疑似簇中的点与正常簇中的点之间的距离,并基于大多数点的共识评估来确定是否保留这些疑似异常点。此方法显著降低了计算负担,同时又保持了数据关键特征和模型敏感度,从而保证高精度的异常点检测结果。此方法的关键流程如图4所示。

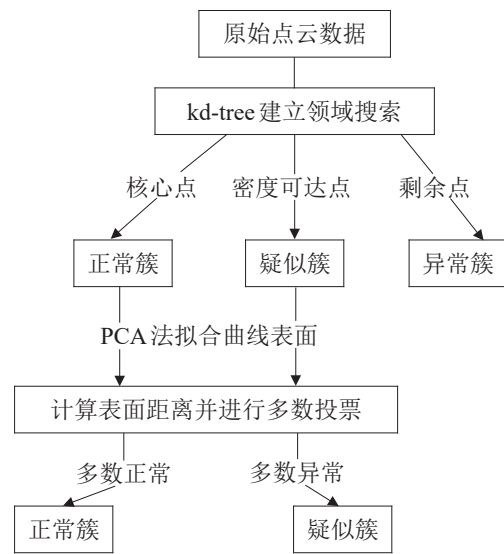


图4 算法流程图

Fig. 4 Algorithm flowchart

3 实验结果与评估

本文采用C++语言编程来实现算法,在搭载Windows10操作系统、AMD 5600H CPU、8GB内存和集成显卡的笔记本电脑上进行开发测试。开

发环境为 Visual Studio 2022, 采用的 PCL 点云库版本为 1.12.0。

对 2 个复杂程度不同的船体曲面分段点云, 通过在点云表面附近随机添加 20 000 个噪声点来模拟扫描获取的点云, 然后利用本文所设计的点云去噪方法, 对 2 个分段的点云进行去噪实验, 得到去噪后的分段点云。为了验证去噪效果, 进一步利用移动最小二乘法将原分段点云模型投影到去噪处理后的分段点云上, 每个原始点云中的点都被投影到其相应的局部拟合曲面上, 计算每个原始点到其投影点的距离, 将这些距离作为点云去噪效果的误差指标验证分段点云的去噪效果。

3.1 船体曲面分段点云获取

船体曲面分段模型如图 5 所示, 利用点云处理软件 CloudCompare 中的 sample 样本点化功能, 将模型转化为点云。再在点云表面添加 20 000 个随机分布的噪声点, 最终生成如图 6 所示的三维点云。




图 5 船体分段模型
Fig. 5 Hull section model

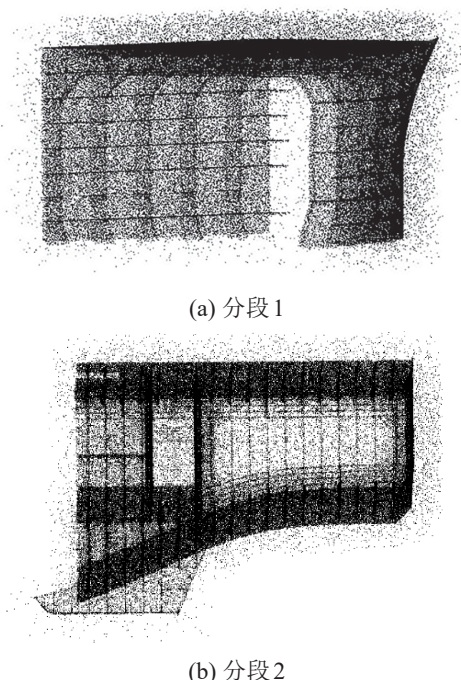


图 6 添加噪声后的分段点云
Fig. 6 Point cloud of hull section with added noise

3.2 分段点云去噪

利用统计滤波对船体曲面分段点云进行初步去噪。通过多次实验, 选定不同 k 值对该模型进行去噪处理, 去噪后点云数量及运行时间与 k 值变化的关系如图 7 所示。当 $k=15$ 时, 点云去噪效果较好, 且用时较短。统计滤波初步去噪后分段点云数据如图 8 所示, 可以看到大尺度噪声已基本被去除。




图 7 k 值对点云去噪效率的影响
Fig. 7 Impact of k -value on point cloud denoising efficiency

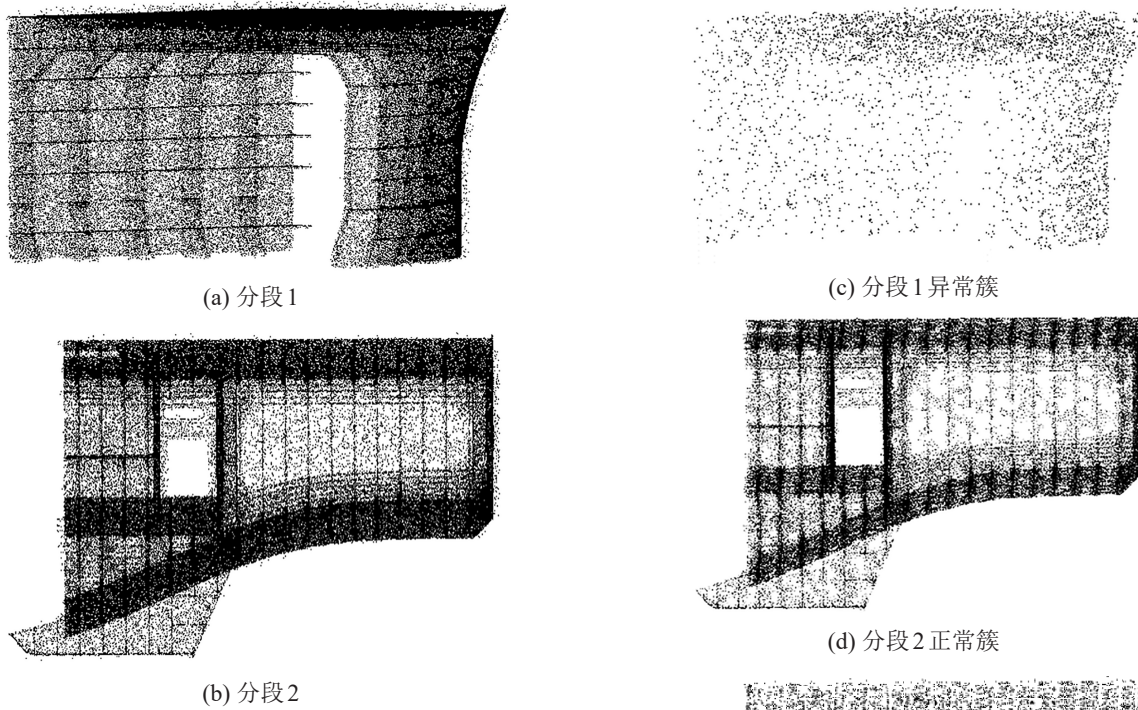


图 8 初步去噪后的分段点云
Fig. 8 Point cloud of hull section after preliminary denoising

第一阶段，采用密度聚类方法对初步去噪后的点云数据进行细分，识别出正常簇、疑似簇及异常簇，筛除异常簇的点云，归类于正常簇的数据用于对疑似簇进行 DCA。分类后的点云如图 9 所示。虽然传统聚类方法在识别异常点方面表现出一定效果，但在处理非孤立异常点时效果则显的有限。


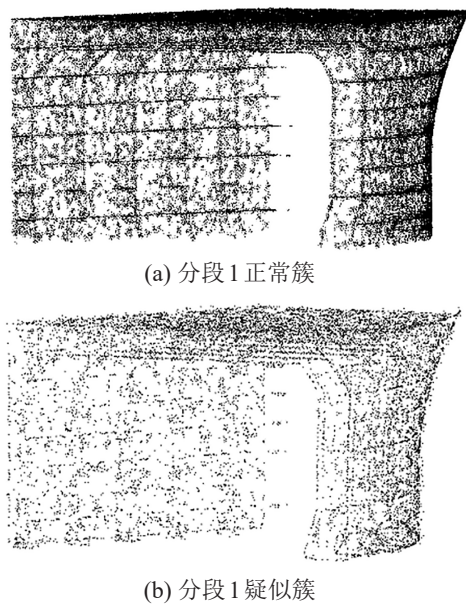


图 9 初步分类后的分段点云
Fig. 9 Point cloud of hull section after preliminary classification



第二阶段，距离阈值参数 x 设置为 2， x 设置过小，会过滤很多正常点； x 设置过大，聚类效果可能不佳，会将异常点判定为正常点。表 2 对比了不同邻近点数 M 下，通过正常簇点云对疑似簇

进行DCA的结果。由于 M 值越大, 曲面拟合效果越好, 但拟合时间也会相应增加。当 M 值在40左右时, 评估效果较好且用时较短。因此, 将邻近点个数 M 的值设为40来对疑似点进行判定, 算法运行后各分类点云数量分布如图10所示。

表2 不同 M 值下点云评估结果Table 2 Evaluation results of point clouds with different M values

M	正常点数	异常点数	运行时间/s
10	9 740	7 602	5.25
15	9 940	7 406	6.54
20	10 460	6 885	7.81
30	11 950	5 391	9.34
40	13 010	4 334	12.84
50	13 250	4 093	24.12
80	13 370	3 973	76.55




图10 不同分类点云数量分布

Fig. 10 Number distribution of different point cloud classifications

通过此方法能有效断开非孤立异常点与正常点之间的关联, 使得那些即便在光滑表面上也难以被识别的非孤立异常点得以从疑似点群中明确区分。图11为经过评估后的正常点云与异常点云。

将第一阶段中的正常簇与第二阶段评估后的正常点云合并, 最终得到去噪后的分段点云, 如图12所示。经过本文去噪算法处理之后, 分段点云中的小尺度边缘噪声已被有效清除, 且在去除噪声点的同时能保持模型形状的完整性, 特征保持效果较好。

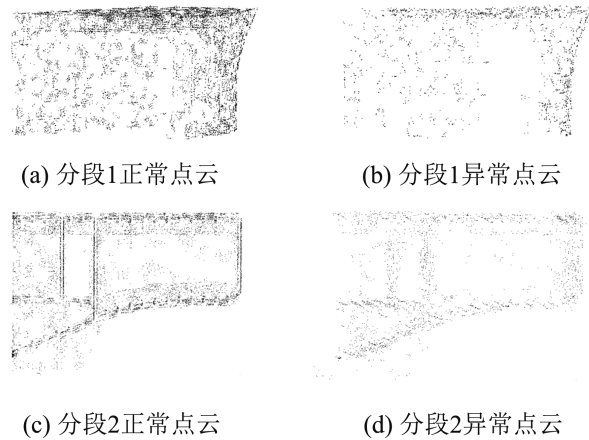
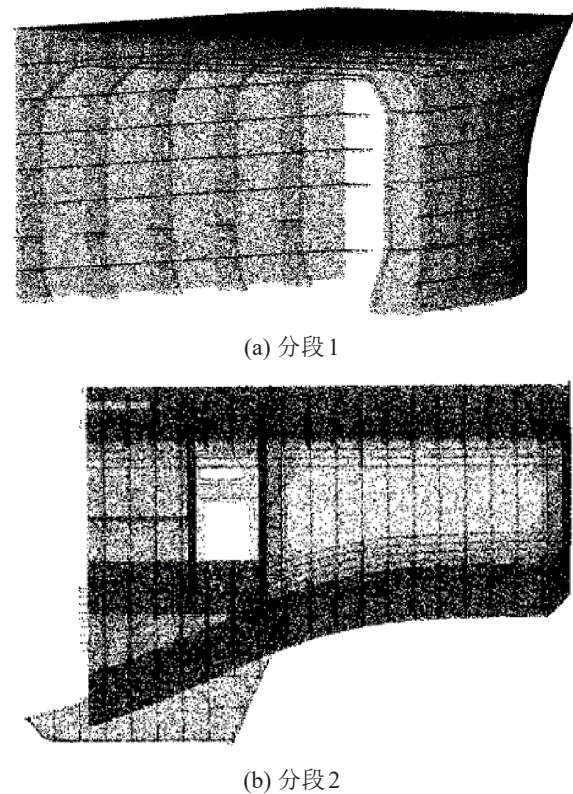


图11 疑似簇距离共识评估后结果

Fig. 11 Results of consensus evaluation of suspected point cloud



(a) 分段1

(b) 分段2

图12 最终合并后的点云

Fig. 12 Processing results of hull section point cloud

3.3 实验结果评估

为了综合评估本文算法的去噪效果, 采用最大误差、平均误差及平均信息熵3个指标来证明其有效性。最大误差和平均误差评估原始点集 S 和简化后点集 S' 之间的几何误差, 反映去噪效果

的优劣，信息熵^[16]反映了点所处区域的无序度，是点特征复杂性的一种表达。

最大误差和平均误差^[17]的计算方法：

$$\Delta_{\max}(S, S') = \max_{q \in S} |d(q, S')| \quad (5)$$

$$\Delta_{\text{avg}}(S, S') = \frac{1}{\|S\|} \sum_{q \in S} |d(q, S')| \quad (6)$$

式中： $d(q, S')$ 为点 q 到简化后点集 S' 上最近点的距离。

平均信息熵的计算公式如下：

$$h_i = R_i / \left(R_i + \sum_{j=1}^k R_j \right) \quad (7)$$

$$h_j = R_j / \left(R_i + \sum_{j=1}^k R_j \right) \quad (8)$$

$$H_i = -h_i \lg h_i - \sum_{j=1}^k h_j \lg h_j \quad (9)$$

$$\bar{H} = \frac{1}{n} \sum_{i=1}^n H_i \quad (10)$$

式中： R_i 和 R_j 分别为点 p_i 及其邻近点 p_j 的曲率； h_i

和 h_j 为点 p_i 及 p_j 的曲率概率分布； H_i 为点 p_i 的信息熵； \bar{H} 为所有点的平均信息熵值。

不同去噪算法的误差如表3所示，计算结果表明，本文算法无论是最大误差还是平均误差，均优于其他2种算法，表明整体去噪性能更优。此外，就平均信息熵而言，本文算法在处理特征丰富的点云数据集后，其信息熵值高于其他算法，表明其在保持点云特征信息方面的能力较为全面。

此外，去噪效率和所需时间也是评估算法效率的重要指标。由表4表明本文算法在去噪比例上较其他算法有明显优势。然而，由于本算法需要针对不同尺度的噪声进行单独去噪，去噪流程较为复杂，并且算法参数中的邻域半径及核心对象数需要先计算所有点距离来进行自适应调整，因此本算法运行时间较文献[6]的算法有所增加，但在实际应用场景中，其运行时间仍处于可接受范围之内。

表3 各算法误差分析

Table 3 Error analysis of each algorithm

点云	点云算法	最大误差/mm	平均误差/mm	平均熵值
分段点云1	半径滤波	0.084	1.62×10^{-2}	3.25×10^4
	文献[6]算法	0.025	6.81×10^{-3}	4.54×10^4
	本文算法	0.017	3.47×10^{-3}	5.81×10^4
分段点云2	半径滤波	0.074	1.58×10^{-2}	3.84×10^4
	文献[6]算法	0.031	7.31×10^{-3}	5.12×10^4
	本文算法	0.019	3.69×10^{-3}	6.55×10^4

表4 各算法效率对比

Table 4 Efficiency comparison of each algorithm

点云	点云算法	点云数量	去噪数量	去噪比例/%	运行时间/s
分段点云1	原始点云	219 991			
	半径滤波	203 548	16 443	82.22	23.45
	文献[6]算法	201 654	18 337	91.67	15.48
	本文算法	200 703	19 288	96.40	17.81
分段点云2	原始点云	219 928			
	半径滤波	202 719	17 209	86.05	25.62
	文献[6]算法	201 983	19 745	89.73	18.73
	本文算法	200 952	18 976	94.88	20.14

4 结论

本文提出的点云去噪算法结合kd-tree空间索引机制和DBSCAN的密度聚类特性, 实现了高效、鲁棒的去噪。通过kd-tree结构优化DBSCAN算法, 提高了孤立点筛选效率并降低了时间复杂度。算法根据核心对象数自适应调整邻域半径, 并利用距离共识评估法增强异常点识别和保留几何属性, 实验表明, 算法在复杂点云去噪和特征保持方面性能较好。

参考文献:

- [1] 陈俊发, 黄港, 陈国仁. 基于三维激光扫描的船舶测量技术[J]. 中国造船, 2020, 33(3): 22-24.
Chen Junfa, Huang Gang, Chen Guoren. Ship Measurement Technology Based on 3D Laser Scanning[J]. China Shiprepair, 2020, 33(3): 22-24.
- [2] 陈俊发, 罗东浩. 三维激光扫描技术在船舶行业的应用[J]. 广东造船, 2018, 37(4): 68-70, 77.
Chen Junfa, Luo Donghao. Application of 3D Laser Scanning Technology in Ship Engineering[J]. Guangdong Shipbuilding, 2018, 37(4): 68-70, 77.
- [3] 杨荣淇, 胡敏捷. 基于海量点云的船舶型线快速确定方法研究[J]. 船舶设计通讯, 2018(2): 101-105.
Yang Rongqi, Hu Minjie. Rapid Modeling Method of Ship Lines Based on Massive Point Cloud[J]. Journal of Ship Design, 2018(2): 101-105.
- [4] Sun Yujing, Schaefer S, Wang Wenping. Denoising Point Sets via L_0 Minimization[J]. Computer Aided Geometric Design, 2015, 35-36: 2-15.
- [5] Mattei E, Castrodad A. Point Cloud Denoising via Moving RPCA[J]. Computer Graphics Forum, 2017, 36(8): 123-137.
- [6] 卢钰仁, 张明路, 吕晓玲, 等. 基于法向修正的双边滤波点云去噪处理[J]. 仪表技术与传感器, 2018(7): 111-115.
Lu Yuren, Zhang Minglu, Lü Xiaoling, et al. Point Cloud Denoising Based on Normal Modification and Bilateral Filtering Processing[J]. Instrument Technique and Sensor, 2018(7): 111-115.
- [7] 范晨, 金永, 刘静静, 等. 装配面点云特征增强的去噪算法研究[J]. 机械与电子, 2022, 40(2): 13-17.
Fan Chen, Jin Yong, Liu Jingjing, et al. Research on Denoising Algorithm for Reature Enhancement of Assembly Surface Point Cloud[J]. Machinery & Electronics, 2022, 40(2): 13-17.
- [8] Hu Wei, Gao Xiang, Gene Cheung, et al. Feature Graph Learning for 3D Point Cloud Denoising[J]. IEEE Transactions on Signal Processing, 2020, 68: 2841-2856.
- [9] 郭进, 陈小宁, 吕峻闻, 等. 采用密度k-means和改进双边滤波的点云自适应去噪算法[J]. 传感器与微系统, 2016, 35(7): 147-149, 153.
Guo Jin, Chen Xiaoning, Lü Junmin, et al. Points Cloud Self-adaptive Denoising Algorithm Based on Density K-means and Improved Bilateral Filtering[J]. Transducer and Microsystem Technologies, 2016, 35(7): 147-149, 153.
- [10] Zeng Jin, Gene Cheung, Michael Ng, et al. 3D Point Cloud Denoising Using Graph Laplacian Regularization of a Low Dimensional Manifold Model[J]. IEEE Transactions on Image Processing, 2020, 29: 3474-3489.
- [11] Muhammad Abeer Irfan, Enrico Magli. Exploiting Color for Graph-based 3D Point Cloud Denoising[J]. Journal of Visual Communication and Image Representation, 2021, 75: 103027.
- [12] 徐志博, 刘永生, 户盼茹. 结合离群因子和K-means++聚类改进的点云去噪算法[J]. 信息技术与信息化, 2023(3): 21-24.
- [13] 戴士杰, 东强, 季文彬, 等. 基于法向修正与位置滤波的散乱点云去噪算法[J]. 传感器与微系统, 2023, 42(2): 130-134.
Dai Shijie, Dong Qiang, Ji Wenbin, et al. Denoising Algorithm for Scattered Point Clouds Based on Normal Correction and Position Filtering[J]. Transducer and Microsystem Technologies, 2023, 42(2): 130-134.
- [14] 陈文龙, 时宏伟. 基于KD树改进的DBSCAN聚类算法[J]. 计算机系统应用, 2022, 31(2): 305-310.
Chen Wenlong, Shi Hongwei. Improved DBSCAN Clustering Algorithm Based on KD Tree[J]. Computer Systems & Applications, 2022, 31(2): 305-310.
- [15] Shi Congming, Wei Bingtao, Wei Shoulin, et al. A Quantitative Discriminant Method of Elbow Point for the Optimal Number of Clusters in Clustering Algorithm[J]. EURASIP Journal on Wireless Communications and Networking, 2021, 2021(1): 31.
- [16] 朱广堂, 叶珉吕. 基于曲率特征的点云去噪及定量评价方法研究[J]. 测绘通报, 2019(6): 105-108.
Zhu Guangtang, Ye Minlü. Research on the Method of Point Cloud Denoising Based on Curvature Characteristics and Quantitative Evaluation[J]. Bulletin of Surveying and Mapping, 2019(6): 105-108.
- [17] 苏本跃, 马金宇, 彭玉升, 等. 基于K-means聚类的RGBD点云去噪和精简算法[J]. 系统仿真学报, 2016, 28(10): 2329-2334, 2341.
Su Benyue, Ma Jinyu, Peng Yusheng, et al. Algorithm for RGBD Point Cloud Denoising and Simplification Based on K-means Clustering[J]. Journal of System Simulation, 2016, 28(10): 2329-2334, 2341.