基于α-Shapes与特征约束的汽车零部件点云孔洞检测方法

古田 王成文 王洋 唐溟伟 金胜熹 孙政

（中国第一汽车股份有限公司，长春 130011）

摘要：为解决汽车零部件三维扫描点云中孔洞检测精度低、鲁棒性差的问题，提出一种融合α-Shapes与几何-拓扑双约束的孔洞检测方法。首先，利用改进的体素滤波对点云进行降噪预处理；随后通过α-Shapes构建多尺度三角网格，结合边界分析提取潜在孔洞区域；最后，引入曲率特征与法向量一致性约束筛选真实孔洞。验证结果表明，在包含30组汽车零部件点云的数据集上，所提出方法的孔洞检测准确率达到97.3%，识别率和效率相较于传统德洛内（Delaunay）算法均有一定提升，并能有效适应复杂曲面与多尺度孔洞场景。

关键词：点云处理 孔洞检测 α-Shapes 特征约束 汽车零部件

中图分类号：TH164 **文献标志码：**B **DOI:** 10.19710/J.cnki.1003-8817.20250178

Hole Detection Method for Automotive Component Point Clouds Based on α-Shapes and Feature Constraints

Gu Tian, Wang Chengwen, Wang Yang, Tang Mingwei, Jin Shengxi, Sun Zheng

(China FAW Group Co., Ltd., Changchun 130011)

Abstract: To address the issues of low accuracy and poor robustness in hole detection within 3D scanned point clouds of automotive components, this paper proposes a hole detection method that integrates α-Shapes with geometric-topological dual constraints. First, an improved voxel filter is used to preprocess the point cloud for noise reduction; Subsequently, a multi-scale triangular mesh is constructed via α-Shapes, and potential hole regions are extracted by combining boundary analysis; Finally, curvature features and normal vector consistency constraints are introduced to screen for real holes. Experimental results show that on a dataset containing 30 groups of automotive component point clouds, the proposed method achieves a hole detection accuracy of 97.3%. Its recognition rate and efficiency are both improved compared with the traditional Delaunay algorithm, and it can effectively adapt to scenarios with complex surfaces and multi-scale holes.

Key words: Point cloud processing, Hole detection, α-Shapes, Feature constraints, Automotive parts

1 前言

汽车关键部件的几何精度直接影响整车装配质量、空气动力学性能及外观品质。随着智能制造与数字化检测技术的发展，基于三维激光扫描的点云数据（Point Cloud）已成为汽车零部件质量检测的核心数据源。然而，受限于扫描设备视角遮挡、材料反射率差异或复杂曲面形貌干扰，点云中常存在局部缺失（孔洞）现象。例如，在发动机罩的边缘区域（如铰链安装孔周边），因金属反光或结构遮挡导致的点云缺失比例可达5%~15%[1]。这些孔洞不仅破坏几何模型的完整性，还

作者简介：古田（1986—），男，工程师，硕士学位，研究方向为汽车尺寸工程数字化。

参考文献引用格式：

古田，王成文，王洋，等. 基于α-Shapes与特征约束的汽车零部件点云孔洞检测方法[J]. 汽车工艺与材料，2026(5): 9-14.

GU T, WANG C W, WANG Y, et al. Hole Detection Method for Automotive Component Point Clouds Based on α-Shapes and Feature Constraints[J]. Automobile Technology & Material, 2026(5): 9-14.

会在后续建模、仿真或自动化装配中引发误差累积，甚至导致碰撞安全性评估失效[2]。

现代汽车制造对零部件的装配间隙要求已提升至±0.5 mm级别，这对点云数据的完整性与精度提出了更高要求。例如，孔洞区域若未被及时检测，可能导致如下问题：

a. 装配偏差。孔洞附近的曲面拟合误差会误导机器人定位，引发间隙不均或密封不良[3]。

b. 仿真失效。在碰撞仿真中，孔洞会破坏应力分布连续性，导致能量吸收能力下降[4]。

c. 逆向工程缺陷。基于点云的CAD模型重建中，孔洞会导致拓扑错误或特征失真[5]。

现有孔洞检测方法主要分为几何驱动与学习驱动2类，但均存在显著瓶颈：

a. 几何驱动方法。德洛内（Delaunay）三角剖分通过边界分析提取孔洞，但对稀疏点云敏感，易误检尖锐边缘（如棱线）为孔洞[6]。球面投影法将点云映射至参数域后检测空洞，但对非规则曲面适应性差。

b. 学习驱动方法。深度学习，如PointNet++可直接分割孔洞区域，但依赖大量标注数据，且难以解释决策逻辑。

α-Shapes[7]通过参数α控制网格密度，理论上可支持多尺度孔洞检测。例如，在汽车零部件中，小孔洞（如直径5 mm的焊点缺失）需较小的α（如α=1 mm），而大范围扫描盲区（如边缘卷边区域）需更大的α（如α=5 mm）。然而，现有研究[6]表明，该方法存在以下问题：

a. 参数敏感性不足。固定α难以适应复杂曲面，易导致局部过拟合或欠拟合。

b. 拓扑误判。曲率突变区域（如R角）的边界可能被误判为孔洞。

c. 计算效率低。大规模点云（如百万级点）的α-Shapes构建耗时可达30 s以上（Open3D测试数据）。

针对上述问题，本文提出一种融合几何特征约束与自适应α优化的孔洞检测方法，以期实现基于点云局部密度与曲率动态调整α，实现复杂曲面的鲁棒网格化，并构建双约束筛选机制，结合曲率特征与法向量一致性，排除尖锐边缘等伪孔洞。

2 孔洞识别

2.1 改进的体素滤波

通过激光扫描设备实测的汽车零部件点云数据可包含百万个以上的点，引入过多点参与运算会给后续重建与配准工作带来困难。体素滤波算法能够进行向下采样减少点云数量。

随机采样[8]是常用的采样方法，Pomerleau[9]使用固定数量点随机采样而不是固定比例，以此来保证不同规模的点云采样得到相同数量的点云，但其结果并不均匀，采样结果的不均匀性和原点云一致。体素降采样[10]将点云划分至n个空间三维体素网格，计算每个体素的重心$P_j\{j=1,2,\cdots,n\}$，该体素内的所有点用重心P_j表示，以达到均匀降采样的目的：

$$P_j(x,y,z)=\left(\frac{1}{m}\sum_{i=1}^{m}x_i,\frac{1}{m}\sum_{i=1}^{m}y_i,\frac{1}{m}\sum_{i=1}^{m}z_i\right) \quad (1)$$

$$P_j=\arg\min\left\|P_j-P_i\right\| \quad (2)$$

式中：m为第n个体素中的点云数量。

但体素降采样获得的点云并非原有的点，而是计算得到的重心，会增加点云配准的误差。本文中提出改进体素降采样算法，利用公式查找降采样后的每个点P_j在原点云中的最近邻点$P_i\{i=1,2,3,\cdots,N\}$并将其替换。改进体素降采样算法采样得到的点依然属于原点云，并且避免了随机采样不均匀的问题。在此基础上再采用固定点云数量采样，使不同点云能采样得到相同数量的点云以保证算法的速度以及算法间的可比性。

汽车零部件点云经过向下采样算法处理后，点云数量由百万级降至万级，甚至千级，且不损失原点云的局部特征。

2.2 α-Shapes构建多尺度网格

2.2.1 算法原理

α-Shapes的核心思想是通过参数α控制点云形状的“紧密度”，其数学基础源自Delaunay三角剖分与空球条件[11]。以下从几何与拓扑角度详细解析其原理。

a. Delaunay四面体化的空球性质。在数学和计算几何中，对于一个给定一般位置的离散点集

P,其Delaunay三角剖分记为$DT(P)$,满足P中的任何点都不在$DT(P)$中的任何三角形的外接圆内。Delaunay三角剖分是三角剖分中所有三角形最小角度的最大化,倾向于避免狭长的三角形出现。对于同一直线上的一组点,不存在Delaunay三角剖分;同一圆上的4个或多个点,存在不唯一的Delaunay三角剖分。通过考虑外切球,Delaunay三角剖分的概念可以扩展到三维和更高的维度上。

首先,由沃洛诺伊(Voronoi)图的对偶图引入Delaunay图的定义,继而引出Delaunay三角剖分的定义。平面离散点集P的Voronoi图是平面的一个子区域划分,其中包含n个子区域,分别对应P中的各基点p所对应的子区域,由平面上以p为最近基点的所有点组成。P的Voronoi图记作$Vor(P)$,与基点p相对应的子区域称为p的Voronoi单元,记作$V(p)$。如图1所示,本文主要研究Voronoi图的对偶图,记作G。其中,对应于每一个Voronoi单元,各有一个节点,若2个单元之间共用一条边,则在这2个单元各自对应的节点之间连接一条弧。因此,对应于$Vor(P)$中的每一条边,G中都有一条弧与之对应。如图1所示,在G的所有界面与$Vor(P)$中的所有顶点之间存在一一对应关系。

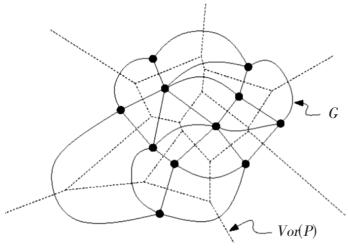


图1　Voronoi图

考察G的直线嵌入。其中,与Voronoi单元$V(P)$对应的节点用点p来实现,而连接$V(p)$和$V(q)$的弧则用线段pq来实现。如图2所示,这一直线嵌入称作P的Delaunay图,记作$DG(P)$。

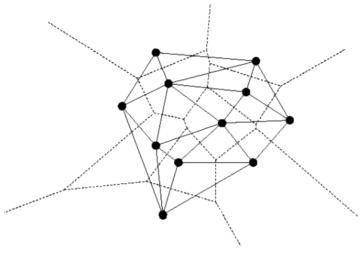


图2　Delaunay图

对于三维点云$P=\{p_1,p_2,...,p_N\}$,Delaunay四面体化生成的每个四面体t_i满足:

$$\forall p_j \in P,\{p_a,p_b,p_c,p_d\},\|x_{t_i}-p_j\| > R_{t_i} \tag{3}$$

式中:x_{t_i}为四面体t_i的外接球球心,R_{t_i}为外接球半径。

在几何意义上,Delaunay四面体化保证网格中无狭长四面体,且每个四面体的外接球内不含其他点。

b. α-Shapes的单纯形筛选。α的空球条件为对于任意单纯形σ(点、边、三角形或四面体),顶点在α趋近于0时独立存在,随α增大逐步与近邻点连接成功;边对应点云的局部线特征,如孔洞边界、棱边,其存在区间反映特征的尺度范围;面或体代表曲面片或空间区域,外接圆或球半径直接关联局部曲率,平坦区域对应大外接圆半径(需保留α_{max}),弯曲区域对应小外接圆半径(α_{min}即可保留)。若存在一个半径为α的球,使该球包含σ的所有顶点且不含其他点,则σ被保留:

$$\alpha-\text{Shape}(P)=\left\{\sigma\subseteq P|\exists x\in \boldsymbol{R}^3,\text{s.t. }\|x-p_i\|\leqslant \alpha\left(\forall p_i\in\sigma\right)\wedge\forall p_j\notin\sigma,\|x-p_j\|>\alpha\right\} \tag{4}$$

Chazal[9]等证明了它的拓扑一致性,当α接近点云采样密度时,α-Shapes能近似保持原始形状的同胚性(Homeomorphism)。

c. 多尺度特性。为覆盖汽车零部件点云的多尺度特征(从毫米级安装孔到分米级整体轮廓),设计对数间隔的α序列为:

$$\alpha_k=\alpha_{\min}\cdot\gamma^{k-1},\quad \gamma=\left(\frac{\alpha_{\max}}{\alpha_{\min}}\right)^{1/(K-1)} \tag{5}$$

式中:α_{min}为点云平均最近邻距离的1/2,确保最小特征被捕捉;α_{max}为点云包围盒对角线的1/4,避免过度膨胀;γ为公比;k为当前索引;K为整个序列元素总数。

α_{min}(如α=1 mm)可保留细节(如小孔洞),但易受噪声干扰;α_{max}(如α=5 mm)可平滑表面,适合检测大范围缺失区域,但可能丢失细节:

$$\alpha_1<\alpha_2\Rightarrow M_{\alpha_1}\subseteq M_{\alpha_2} \tag{6}$$

式中:M_α为α-Shapes生成的网格,α越大,网格越"稀疏"。

2.2.2　算法流程

α-Shapes算法流程如下:

a. 输入预处理。使用改进的体素滤波，将点云划分为体素格，对每个体素内的点计算协方差矩阵：

$$C = \frac{1}{k}\sum_{i=1}^{k}(p_i - \mu)(p_i - \mu)^T \tag{7}$$

式中：μ 为均值，保留满足特征值 $\lambda_{min}>\tau$ 的体素；τ 为预设的阈值，以此来保留边缘细节。

b. 构建 α-Shapes 网格。首先对预处理后的点云 Delaunay 四面体化，生成四面体网格 T，然后遍历所有四面体网格 T，计算其外接球半径 R_i，保留 $R_i \leq \alpha$ 的四面体，生成 T_α，最后统计每个三角面被共享的次数，保留共享次数为1的三角形，构成网格 M_α。

c. 自适应 α 调整策略。首先进行局部曲率约束调整 α，计算点 p_i 的邻域点 $N(p_i)$，利用式(8)和式(9)分别构造协方差矩阵 C_i 和计算曲率 K_i，其中 μ_i 为邻域均值，$\lambda_{max}\geq\lambda_{mid}\geq\lambda_{min}$ 为特征值，利用式(10)根据对应点的曲率 K_i 来调整 α。然后再根据点云密度 p 进行补偿，由式(11)计算点的邻域密度，式中 r 为邻域半径，再根据点云密度由式(12)调整 α。

$$C_i = \frac{1}{k}\sum_{j\in N(p_i)}(p_j - \mu_i)(p_j - \mu_i)^T \tag{8}$$

$$K_i = \frac{\lambda_{min}}{\lambda_{max} + \lambda_{mid} + \lambda_{min}} \tag{9}$$

$$\alpha'(p_i) = \alpha_0 \cdot (1 - K_i) \tag{10}$$

$$\rho(p_i) = \frac{k}{V_{sphere}}, \quad V_{sphere} = \frac{4}{3}\pi r^3 \tag{11}$$

$$\alpha'(p_i) = \alpha_0 \cdot \left(1 + \frac{\rho_{max} - \rho(p_i)}{\rho_{max}}\right) \tag{12}$$

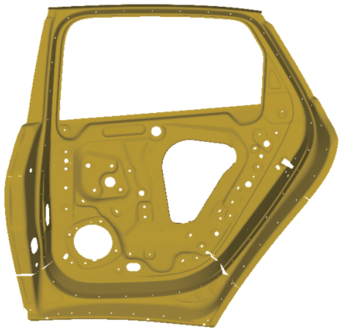
式中：α_0 为初始参数值；V_{sphere} 为邻域球体体积；ρ_{max} 为点云最大密度。

3 仿真试验验证

本文对汽车零部件点云孔洞的识别验证在 Visual Studio 2022 软件中借助点云库(Point Cloud Library. PCL)开源点云处理三方库进行点云孔洞识别。试验点云对应如图3所示汽车的3种零部件，零件1~零件3分别包含约10万个、100万个和600万个三坐标点。汽车零件点云采用3D激光扫描设备生成，所以点集的大小取决于相机的分辨率和零件大小，相机的分辨率均为百万级别，采用上文提到改进的体素滤波算法进行下采样，既能精简数据又能保持原点云结构不变。滤波后3种零件的点云中点的数量为约1万个、10万个和120万个三坐标点。



(a)零件1



(b)零件2



(c)零件3

图3 零件点云

汽车零部件点云的孔洞从形态上可以分为规则和非规则，大尺寸和小尺寸的形状，所以本文的试验主要分析这4种形状孔洞识别的正确率。从图4中可以看出4种不同类别孔洞形状。

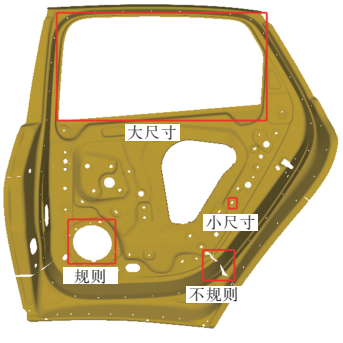
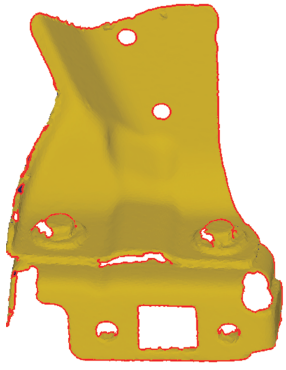
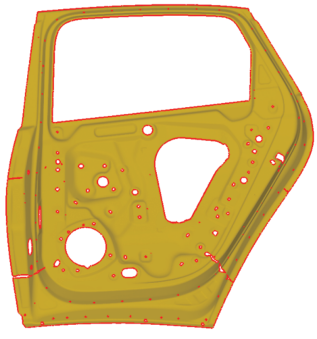


图4 孔洞形状

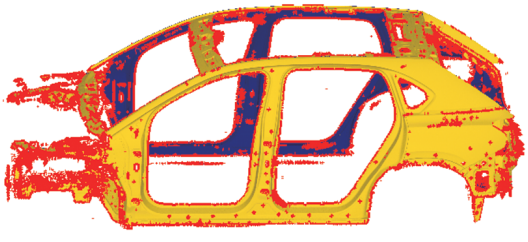
模板点云数据和目标点云数据的初始位置关系如图5所示,其中零件1由CAD模型转换得到,目标点云数据由三维扫描设备扫描实车得到。3种不同零件经过本文孔洞识别算法处理后,在每个孔洞轮廓上用红色曲线标记。3种零件识别结果如图5所示,可以看出各类孔洞均可识别。



(a)零件1



(b)零件2



(c)零件3

图5　孔洞识别效果

为验证本文算法对于实测点云数据在孔洞识别上的正确率,以上述3种零件进行30组实测试验,分别统计每一种零件4种不同类型孔洞识别的正确率,结果如表1所示。由表1可知,规则孔洞识别成功率略高于不规则孔洞,大尺寸孔洞的成功率略高于小尺寸孔洞,成功识别孔洞的总正确率达到96%以上,满足工业需求,验证了本算法对孔洞识别具有很高的识别率。

表1　三种零件孔洞识别的正确率　%

零件类别	规则孔洞	不规则孔洞	大尺寸孔洞	小尺寸孔洞
零件1	98.3	97.7	99.1	97.8
零件2	98.5	97.6	99.3	98.1
零件3	98.1	97.3	99.1	97.8

虽然深度学习如PointNet++算法具有较高的识别率和效率,但需要大量的数据进行标注以及算法需要较好的决策功能,而常用的点云处理软件不需要实时性,往往为离线操作,所以本文算法只需要与经典的Delaunay算法进行横向对比。为验证本文算法相较于Delaunay算法对孔洞识别的效率和正确率,分别对上述3种零部件进行孔洞识别试验,2种算法试验结果如表2所示,从试验结果上看,对3种大小和复杂程度不同的零件,本文算法在孔洞识别率和算法耗时方面相较于Delaunay算均都有显著提升。

表2　2种算法孔洞识别性能对比

零件类别	本文算法正确率/%	本文算法耗时/s	Delaunay算法正确率/%	Delaunay算法耗时/s
零件1	98.6	3.5	92.6	15.3
零件2	98.5	11.2	91.5	40.2
零件3	98.1	33.0	90.3	95.3

4　结束语

为解决传统方法在汽车零部件的复杂曲面场景下的漏检、误检以及效率低等问题,本文提出一种结合α-Shapes与几何-拓扑双约束的孔洞检测方法,对3种不同尺度和复杂程度汽车零部件进行孔洞识别试验,结果表明,对于任意形状的孔洞,正确识别率都达97.3%以上,识别率和效率相较于传统算法均有一定幅度的提升,能满足工业上汽车零部件点云在虚拟装配等软件中孔洞识别的要求。未来工作将探索深度学习与物理约束的联合建模,进一步提升方法在动态场景中的泛化能力。

参考文献:

[1] ZHANG Y. Impact of Scan Data Quality on Automotive Panel Assembly[J]. Journal of Manufacturing Science and Engineering, 2021, 143(8).

[2] WANG X. Effect of Data Incompleteness on Crash Simula-

tion Accuracy[J]. International Journal of Crashworthiness, 2020, 25(6): 678-689.

[3] PARK S, LEE K. Impact of Point Cloud Holes on Robotic Path Planning[J]. Robotics and Computer-Integrated Manufacturing, 2019, 58: 234-245.

[4] NIUTTA C B, CIARDIELLO R, BERTO F, et al. On the Influence of Additive Manufacturing Defects on the Energy Absorption Capability of A Lattice Structure[J]. Procedia Structural Integrity, 2022(42): 1449-1457.

[5] 王春香, 孟宏, 张勇, 等. 逆向工程中点云孔洞修补技术研究[J]. 机械科学与技术, 2018, 37(5): 729-735.

[6] GOPI M, KRISHNAN S, SILVA C T. Surface Reconstruction Based on Lower Dimensional Localized Delaunay Triangulation[J]. Computer Graphics Forum, 2000, 19(3): 1-8.

[7] EDELSBRUNNER H, MÜCKE E P. Three-dimensional Alpha Shapes[J]. ACM Transactions on Graphics, 1994, 13 (1): 43-72.

[8] ZHOU Y, WANG W. Adaptive Alpha Shapes for Point Cloud Hole Detection[J]. Computers & Graphics, 2020, 89: 102-113.

[9] POMERLEAU F, COLAS F, SIEGWART R. A Review of Point Cloud Registration Algorithms for Mobile Robotics[J]. Foundations & Trends in Robotics, 2015, 4: 1-104.

[10] 张彬, 熊传兵. 基于体素下采样和关键点提取的点云自动配准[J]. 激光与光电子学进展, 2020, 57(4): 109-117.

[11] CHAZAL F, LIEUTIER A, CHAZAL P. Topology Guaranteeing Manifold Reconstruction Using Distance Function[J]. ACM Symposium on Computational Geometry, 2006: 112-118.

AT&M