

航空发动机外形点云的特征分割方法

闫杰琼, 周来水*, 胡少乾, 文思扬

南京航空航天大学机电学院, 江苏 南京 210016

摘要 目前我国存在较多外购发动机的情况, 外购发动机存在只有实物及安装尺寸等信息, 而没有三维数字化模型的问题, 这给飞机与发动机的装配协调设计带来较大困难, 因此飞机设计部门对快速重构航空发动机的外形几何模型提出了迫切需求。为了使重建出的发动机外形几何模型尽可能地保留准确的结构特征, 提出了一种基于深度学习的航空发动机外形点云特征分割方法, 该方法将整体点云分割成特征数据与非特征数据, 这有利于后续采用不同的方法重建出各种复杂的结构特征。设计了一种迭代密度均衡算法用于构建特征分割数据集, 该算法为特征分割网络的训练、测试和性能评估提供基础; 设计了一种特征分割网络, 从多尺度局部表面片中收集形状结构和局部邻域信息, 用于判断其中心是否是特征点。将训练好的特征分割网络模型应用于发动机外形点云, 验证结果表明, 特征分割精度达到 95.16%, 所提算法实现了高精度语义分割。

关键词 机器视觉; 航空发动机; 外形点云; 深度学习; 特征分割

中图分类号 V228.4

文献标志码 A

doi: 10.3788/AOS202242.0715001

Feature Segmentation Method of Aero-Engine Profile Point Cloud

Yan Jieqiong, Zhou Laishui*, Hu Shaoqian, Wen Siyang

College of Mechanical & Electrical Engineering, Nanjing University of Aeronautics and Astronautics,
Nanjing, Jiangsu 210016, China

Abstract At present, many domestic aero-engines are bought from abroad. Only physical objects and installation dimensions are provided for such aero-engines, and the lack of three-dimensional digital models brings great difficulties to the assembly coordination design of aircraft and aero-engines. Therefore, aircraft design departments urgently need to quickly reconstruct geometric models of aero-engine profiles. To enable a reconstructed geometric model of the aero-engine profile to retain exact structural features, this paper proposes a feature segmentation method of the aero-engine profile point clouds based on deep learning. It divides the whole point clouds into feature data and non-feature data, which is conducive to the subsequent reconstruction of various complex structural features by different methods. An iterative density equalization algorithm designed to create a feature segmentation dataset provides a basis for the training, testing, and performance evaluation of the feature segmentation network. A feature segmentation network is designed to collect the shape structure and local neighborhood information from multi-scale patches and thereby determine whether the center is a feature point. The trained feature segmentation network model is then applied to the profile point cloud of an aero-engine. The verification results show that the accuracy of feature segmentation reaches 95.16%, which means the proposed algorithm achieves high-precision semantic segmentation.

Key words machine vision; aero-engine; profile point cloud; deep learning; feature segmentation

收稿日期: 2021-07-09; 修回日期: 2021-08-14; 录用日期: 2021-09-27

基金项目: 国家科技支撑计划 (2020YFB2010702)

通信作者: *zlsme@nuaa.edu.cn

1 引 言

由于我国航空发动机的设计制造还不能满足国产飞机的生产需求,因此,目前我国还存在较多外购发动机的情况。我国的飞机设计制造已全面采用三维数字化技术,而外购发动机存在只有实物及安装尺寸等信息,没有发动机的三维数字化模型的问题,这给飞机与发动机装配协调设计带来较大困难。因此,飞机设计部门对快速重构航空发动机外形几何模型、为飞机设计提供航空发动机的数字化协调样机提出了迫切需求。

从航空发动机实测点云出发,关于重建其三维几何模型的研究主要集中于单个零部件,较少针对整体外形几何模型的重建。针对发动机叶片疲劳损伤,李景俊等^[1]提出了一种缺陷孔洞边界特征点的提取算法,该算法有助于快速重建曲面模型;针对发动机叶片断裂、划道、形变等损伤,张鹏程等^[2]提出了一种激光交叠式三维重建方法,该方法可以从实测点云中重建出叶片的三维模型,有助于后期采用激光熔覆技术对损伤部分进行修复;发动机机匣形状复杂且壁薄,在加工过程中极易产生变形,李中伟等^[3]利用自动化三维测量设备重建机匣内外三维点云,检测关键部位的几何尺寸,以保证加工精度;PartInspect L 系列的测量设备^[3]可以重建出发动机叶盘零部件的轮廓形状和细节特征并进行误差分析;刘元朋等^[4]提出了一种航空发动机管路测量数据的分割方法,用于提高管路的反求建模效率。

航空发动机的外形点云大致分为机匣装配体和管路系统两部分,包括机匣壳体、管路、凸台、加强筋、成附件、管接头、卡箍等结构特征,它们起承力、包容、连接、密封和固定作用。相比于形状规则简单的机匣壳体与管路,凸台、加强筋和成附件等结构包含丰富的细节形状。除去对象本身的形状特点以外,实测数据中的噪声、数据缺失和分布不均匀等缺陷也会给重建带来很大的困难。基于表面连续性假设的重建算法直接处理外形点云时,会模糊甚至破坏这些结构特征。因此,为了尽可能重建出准确的发动机外形几何模型,需要研究一种特征分割方法,将外形点云分割成包含确切语义信息的数据块,明确指向发动机的各种结构特征,这有利于在分类预处理实测数据的诸多缺陷之后,再采用不同的重建方法去实现点云模型的精度重构。

现有点云分割方法可大致分为传统方法和基

于深度学习的方法^[5]。传统方法中基于边缘的分割方法^[6]的结果会受噪声和点云分布不均匀的影响。基于聚类的分割^[7-9]是将具有相似性特征的数据点进行聚类的过程,其实现的前提是不同类中数据点几何特征参数的相似性应尽量低^[10]。区域生长法^[11]结果的好坏取决于种子点的选取。模型拟合法^[12-14]更适用于从点云中提取平面、柱面和球面等规则形状的几何基元^[15]。上述方法应用于发动机外形点云时,不可避免地存在过分割和欠分割的问题,并且还需要对其结果进行进一步的手动标注才能包含确切的语义信息。

近十年来,随着海量数据累积和人工智能技术的发展,深度神经网络得到了较为广泛的应用^[16]。标准深度神经网络需要有规则结构的输入数据^[17],将其直接应用于点云时,卷积操作会产生错误的计算结果^[18]。Voxel-based 方法是将点云转化为三维体素^[19],再用深度学习进行处理^[20-21],这类方法往往有较大的内存需求,需要人机交互,且受分辨率的影响,其很难捕捉到细粒度的特征。

2017 年,Charles 等^[22]提出了可以直接处理点云的网络结构 PointNet 和 PointNet++^[23]。PointNet 用整体点云作为输入,先从每个点抽象出空间编码,然后用对称函数将其整合成全局特征,该方法实现了排列不变性,在 ModelNet40^[21] 对象分类、ShapeNet^[24] 部件分割和 Stanford 3D^[25] 场景分割任务中取得了不错的效果,但由于该方法缺少对局部几何信息的学习,所得结果还有提升的空间。在此基础上,PointNet++ 改进为从整体点云中选择一部分点作为局部表面片(patch)的中心,分别进行球邻域搜索,将整体点云划分成相互重叠的局部表面片作为网络输入。在与 PointNet 相同的分类和分割任务中,PointNet++ 将从 patch 中抽象出的特征向量按照距离权重从中心传播给 patch 中的其他点,然后预测 patch 中每个点属于不同类别或者不同数据块的概率,所得结果有了一定程度的优化,但是传播过程中 patch 内部形状变化处的点被赋予了错误的特征信息,这限制了结果的优化程度。后续在 PointNet 基础上提出的算法^[26-28]考虑了点的局部邻域信息^[29],让网络有了探索局部特征的可能,所得结果有变好的趋势,但是为了保证排列不变性,该算法依旧是对单个点进行处理,这从根本上忽视了点与点之间的空间几何关系即局部形状的本质,限制了网络根据局部形状差异进行数据分割的能力。

2 特征分割方法

2.1 特征分割标准

为了重建出准确的发动机外形几何模型,根据每种结构特征重建方法的不同对其进行了分割。图 1 为发动机的照片和实测点云,其中机匣壳体一般是圆筒形或圆锥形的薄壁筒体,可以在基元分割的基础上,采用圆柱面和圆锥面拟合的方式进行重建,管路通常以弯曲的圆柱形状描述,经分割后可获取轴线和截面圆,通过扫掠即可完成建模,将上述两种结构特征划分为非特征数据;各种形状复杂的密封件、支架和卡箍通常是标准件,可以通过形状检索从标准件库中选择相似模型进行变形建模。针对包含丰富细节形状的异形凸台、加强筋、成附件等,可以采用 B 样条曲面逼近的方法以得到尽可能准确的外形模型,将上述结构特征划分为特征数据。

2.2 特征分割难点

利用现有分割方法处理外形点云很难获得满意结果的原因包括:点云自身的形状特性和实测数据的诸多缺陷。一方面,航空发动机零部件数目庞大、结构复杂,其外形点云的特性如图 2 所示。5 种机匣的特征和非特征数据相互之间存在形状差异,同种数据内部还存在多种形状变化,这些都会被现有方法认为是数据分割的内容,输出过分割结果;现有方法中的局部形状描述子对细节形状的表达不够充分,会造成没有规律的欠分割;另一方面,实测点云

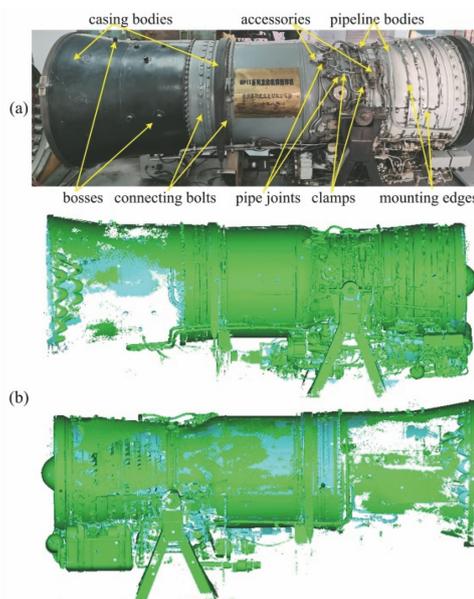


图 1 航空发动机。(a)照片;(b)实测点云
Fig. 1 Aero-engine. (a) Photograph;
(b) measured point clouds

不可避免地包含一定的噪声,而且测量设备距离被测对象的远近会引起数据分布不均匀,管路系统铺设于机匣外部 1/3 的圆周区域内,导致测量设备不可达,造成大片的数据缺失。

2.3 特征分割流程

如图 3 所示,特征分割方法的两个重要组成部分是特征分割网络和特征分割数据集,其实质是一个先训练再求解的过程,具体步骤如下:

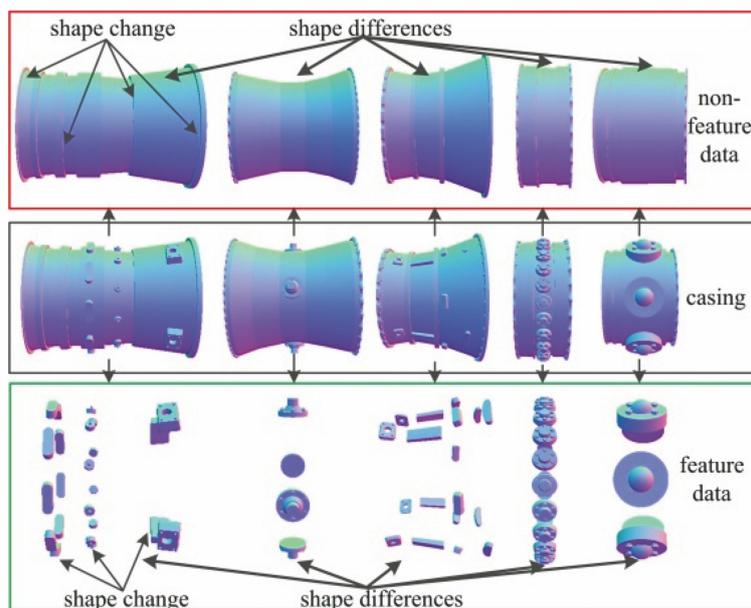


图 2 航空发动机外形点云的形状特性
Fig. 2 Shape characteristics of aero-engine profile point cloud

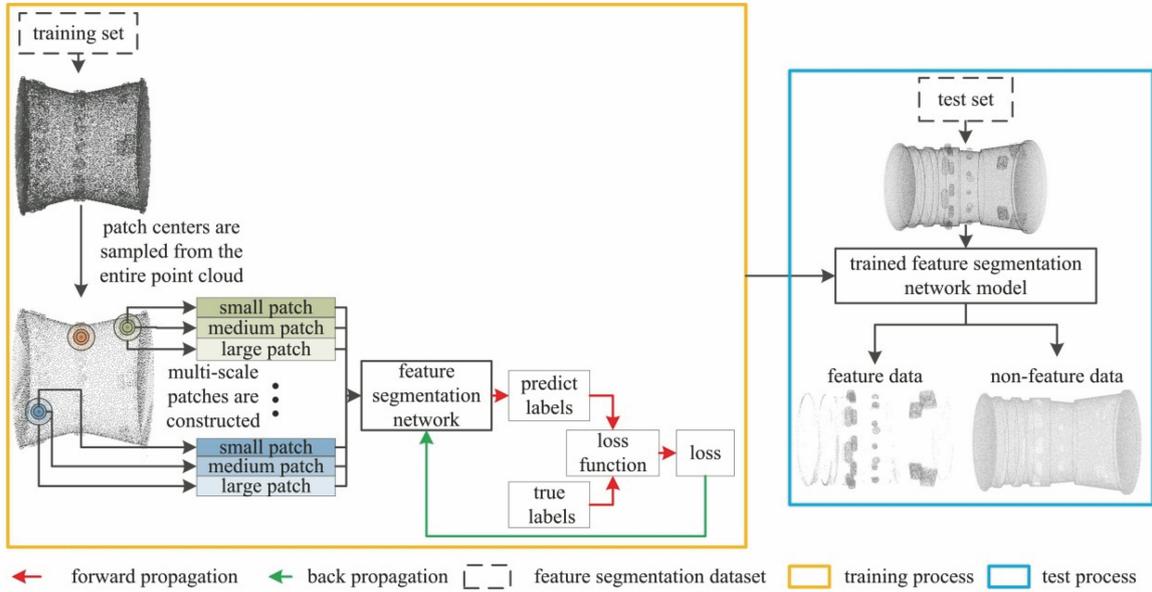


图 3 特征分割方法

Fig. 3 Feature segmentation method

1) 从特征分割数据集的训练集中选择一个整体点云, 利用 IFPS (iterative farthest point sampling) 方法^[23]选择局部表面片中心;

2) 在 patch 中心处根据球邻域搜索半径的不同, 构建多尺度局部表面片作为特征分割网络的输入;

3) 特征分割网络综合从多尺度局部表面片中收集到的形状结构和局部邻域信息, 生成 patch 中心的预测标签;

4) 利用损失函数统计预测标签和真实标签之间的误差, 将其反向传播给分割网络;

5) 重复步骤 1)~4), 观察损失函数的收敛情况, 当损失不再减小时, 结束训练;

6) 从测试集中选择待分割的发动机外形点云,

输入训练好的特征分割网络模型, 每个点都作为 patch 中心, 即可获得分割结果。

3 特征分割网络

给定一个包含 n 个点的整体点云 $X = \{p_1, p_2, \dots, p_n\} \subseteq \mathbf{R}^F$, 每个点有 F 个维度的输入信息, 当 $p_i = (x_i, y_i, z_i)$ 时, $F = 3$, 选择 m 个点 $\{p_1, p_2, \dots, p_m\}$ 作为局部表面片的中心 p_i , 通过在 p_i 处进行三次球邻域搜索, 得到三种不同尺度的局部表面片 small patch (P_s), medium patch (P_m), large patch (P_l), 如图 4 所示, 其中 k_s, k_m, k_l 分别表示每种尺度的局部表面片中包含的点数。从每种尺度的局部表面片集合中, 选择 B 个组成 mini-batch, 作为特征分割网络的输入。特征分割网络通过训练一个

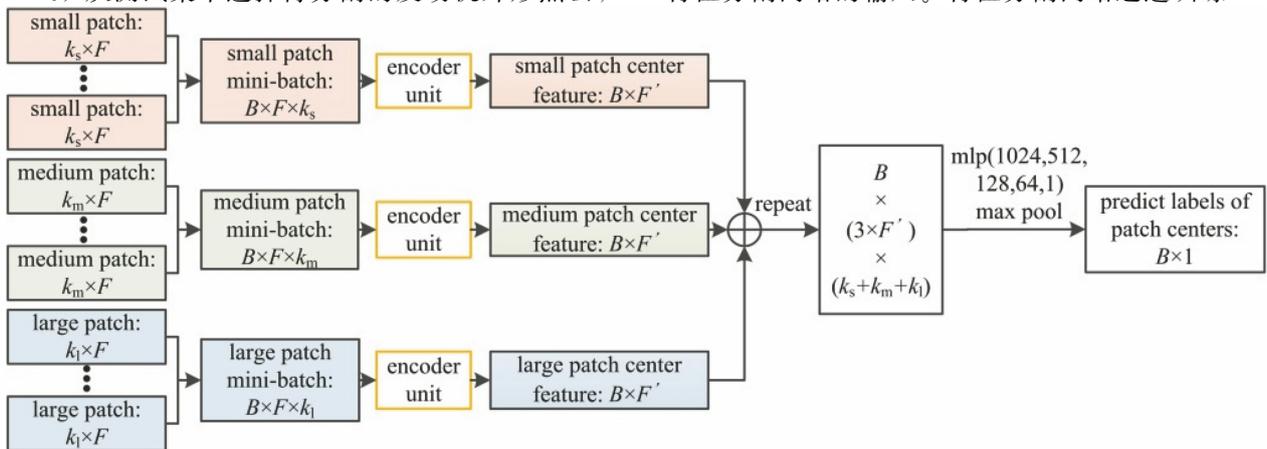


图 4 特征分割网络

Fig. 4 Feature segmentation network

非线性函数 g 来识别局部表面片的中心 p_i 是否是特征点。

$$\tilde{f}_i = g(P_s, P_m, P_l), \quad (1)$$

式中： \tilde{f}_i 是特征分割网络预测 p_i 是特征点的概率，当 $\tilde{f}_i > 0.5$ 时， p_i 被识别为特征点，否则被识别为非特征点。结合图 3、4 可知，特征分割网络先通过局部信息编码单元(encoder unit)从多尺度局部表面片中尽可能多地编码形状结构和局部邻域信息，通过将其映射到高维特征空间得到 F' 维的特征向量；然后利用多层感知机(mlp)生成局部表面片中心的预测标签，在真实标签的监督下，利用损失函数将误差反向传播，通过更新网络参数，引导其调整特征向量之间的距离，改变点与点之间的语义相似性。

在训练过程中，高维特征空间是动态变化的，其中：相同真实标签的点与点之间，特征向量的差异在减小；不同真实标签的点与点之间，特征向量的差异在增大。网络训练的过程就是将真实标签包含的语义信息逐渐融入网络模型参数的过程。

训练完的特征分割网络模型实质是一种从现实世界到高维特征空间的映射，将局部形状映射成特征向量，将语义相似性高的点归为一类，作为现实世界中的一种语义结构，将语义相似性低的点分到不同集合，以呈现出语义分割结果。

在局部表面片中心 p_i 处进行球邻域搜索，得到的 $p_{j_1}, p_{j_2}, \dots, p_{j_k}$ 是 p_i 的 k 个球邻域点，构建局部表面片 $P = \{p_i, p_{j_1}, p_{j_2}, \dots, p_{j_k}\} \subseteq \mathbf{R}^F$ (F 为维数)，encoder unit 定义一个集函数 $f: \mathbf{R}^F \rightarrow \mathbf{R}^{F'}$ ，把 patch 抽象成一个 F' 维的向量：

$$f\{p_i, p_{j_1}, p_{j_2}, \dots, p_{j_k}\} = \gamma\{\text{MAX}_{j=j_1, j_2, \dots, j_k} \{h(p_i, p_j - p_i)\}\}, \quad (2)$$

式中： γ 和 h 是多层感知机网络。

将网络处理的数据单元从单个点 p_i 调整成 $(p_i, p_j - p_i)$ ，同时编码局部表面片的形状结构(通过 p_i 的坐标进行捕捉)和局部邻域信息(通过 $p_j - p_i$ 来捕捉)。这个集函数 f 的结果不会因为局部表面片中点的排列顺序变化而发生变化，满足排列不变性。

如图 5 所示，encoder unit 首先通过一个空间转换(ST)网络把输入的局部表面片在基准空间对齐，然后用 EdgeConv^[30] 去编码局部邻域信息，分别得到三种局部特征：低级特征(low-level feature: $B \times 64 \times k$)、中级特征(mid-level feature: $B \times 64 \times k$)和高级特征(high-level feature: $B \times 128 \times k$)，将最深的高级特征与浅层网络学习到的低级和中级特征合并之后，利用多层感知机进一步抽象形状信息，最大池化出局部表面片特征(patch feature: $B \times 1024$)。图 6 为 encoder unit 学习到的特征。局部特征为表达细节形状的关键点，越底层的局部特征，越贴近模型表面，越能表达真实的细节形状，而局部表面片特征表达的是整体形状变化趋势[图 6(a)、(c)和(d)]。在此基础上，encoder unit 将局部表面片特征重复 k 次后成为 $B \times 1024 \times k$ 的特征向量，将其与之前的局部特征按照第二个维度串联在一起，得到 $B \times 1280 \times k$ 的特征向量，再最大池化出局部表面片中心特征($B \times F'$, $F' = 1280$)，这一过程进一步将局部邻域信息和整体形状变化趋势抽象成局部表面片的形状结构。

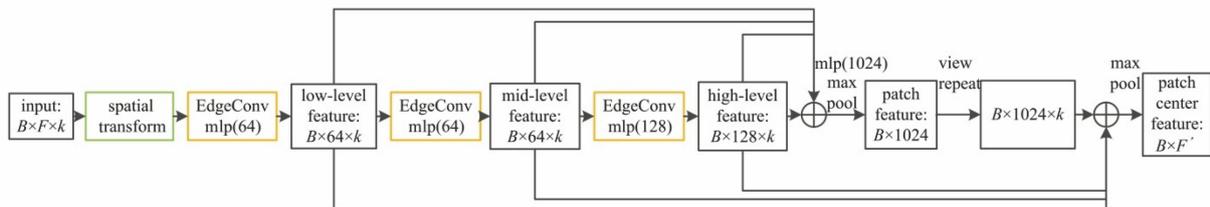


图 5 局部信息编码单元

Fig. 5 Local information coding unit

空间转换网络(图 7)和 EdgeConv(图 8)中的 q -nn graph 表示将局部表面片中的每个点都作为一个选中点，然后计算局部表面片中每个剩余点特征到选中点特征之间的距离，按距离由小到大进行排序，前 q 个点成为选中点的 q 个最近邻点。 q -nn graph 输出的第二个通道是 $2 \times f$ 维特征，前 f 维是

每个选中点的特征，后 f 维是 q 个最近邻与选中点的特征差。

4 特征分割数据集

本文选取的应用实例是航空发动机外形点云整体机匣中特征区与非特征区的分割。特征分割数据

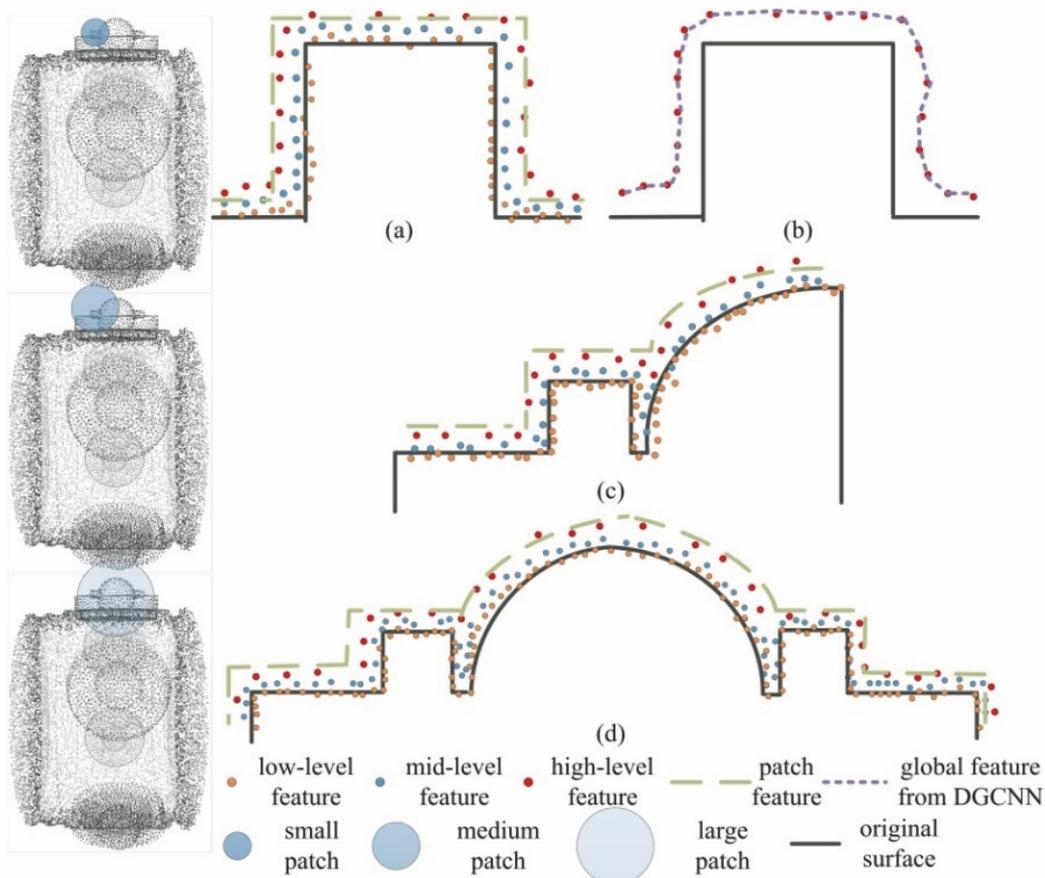


图 6 Encoder unit 学习到的特征。(a)小尺度 patch;(b)来自 DGCNN^[31]的全局特征;(c)中尺度 patch;(d)大尺度 patch
 Fig. 6 Features learned by encoder unit. (a) Small patch; (b) global feature from DGCNN^[31];
 (c) medium patch; (d) large patch

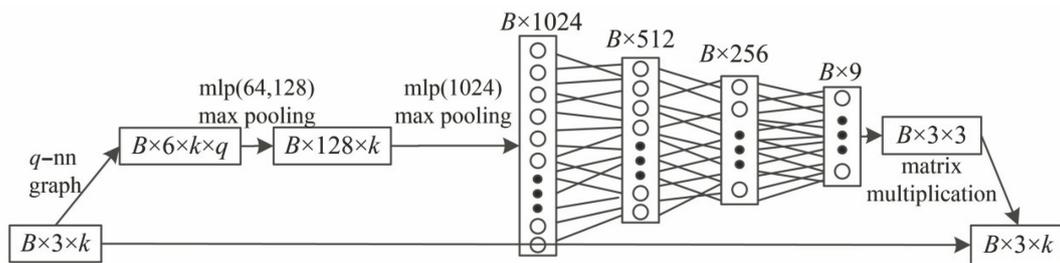


图 7 空间转换网络
 Fig. 7 Spatial transform network

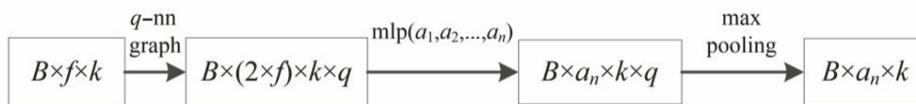


图 8 EdgeConv 网络
 Fig. 8 EdgeConv network

集需要保证数据本身具有代表性、丰富性、真实性、准确性和均衡性。

1) 代表性:从发动机外形点云中挑选典型结构特征的几何形状,构建特征和非特征模板。

2) 丰富性:观察和收集尽量多的航空发动机实物照片和点云数据(图 1),作为构建模板的参考。数据集中包含的结构特征形状越丰富,训练完的网络模型越有可能完成不同类型的发动机外形点云的

特征分割任务。

3) 真实性:一方面体现在模板的形状要贴近真实的发动机外形,另一方面体现在要往合成数据中添加实测点云的各种数据缺陷,以提高网络应对实测数据的鲁棒能力。

4) 准确性:深度神经网络对错误标签是有一定应对能力的,但是只有标签数据尽可能准确地对应点云,才会在训练过程中给予网络正确的引导,起到切实的监督作用。

5) 均衡性:分割数据集中,特征数据与非特征数据不能出现明显的密度差异,否则网络学习就不再是区分形状差异而是区分密度差异,即将整体点云一分为二。

4.1 迭代密度均衡算法

图 9 为机匣点云对比。整体机匣的特征区和非

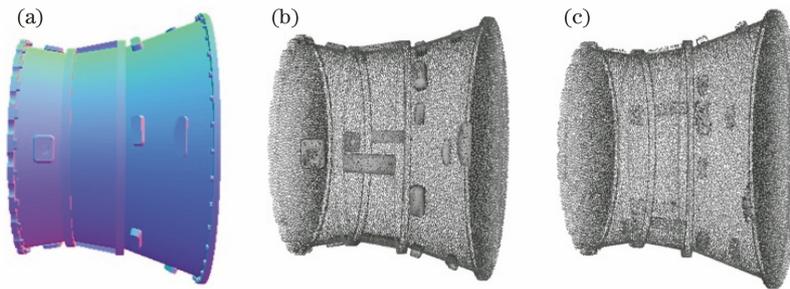


图 9 机匣点云对比。(a)原始模型;(b)未采用和(c)采用密度均衡算法的电云

Fig. 9 Casing point cloud comparison. (a) Original model; point clouds obtained by algorithms (b) with and (c) without density equalization algorithm

4.2 模拟实测数据缺陷的方法

特征分割是重建航空发动机外形几何模型的第一步,实测数据的噪声、缺失、分布不均匀等缺陷都是在特征分割的基础上进行预处理的。为了增强分割网络对实测数据诸多缺陷的适应性,选择在合成数据的基础上添加实测数据的上述缺陷。没有将如图 1 所示的实测数据加入训练集的原因是:1)受表面材质的影响,测量数据存在大片的数据缺失,不能充分展示发动机机匣的形状特点;2)发动机机匣自身的复杂性和庞大的数据量都给人工选取特征数据和非特征数据带来很大的困难,在此基础上制作标签信息会不可避免地引入噪声标签。噪声标签的判断标准是点的标注标签与真实标签相反。噪声标签在训练集中达到一定比例时,会误导网络学习,给分割网络的学习带来以下不利影响:

1) 噪声。设点云边界包围盒对角线的长度为 b ,控制每个点沿着法线方向有 b 的 $0\% \sim 0.1\%$ 的随机移动量。

特征区的体积相差较大,当选择适合非特征的数据密度时,各种结构特征的细节形状没有被充分表达,影响网络利用特征内部形状变化对 patch 中心是否是特征点的判断;当选择适合特征的数据密度时,非特征数据会过度冗余,导致网络在包含相似形状信息的点处进行多次训练,这在影响训练速度的同时,对分割网络的学习也无过多增益;如果采用特征区与非特征区有明显密度差异的整体机匣[图 9(b)]来训练分割网络,最终网络学习到的不再是两部分的形状差异而是各自的密度差异,这样训练出来的网络是没有意义的,其原因是实测数据通常不会存在这样规律的密度差异。本文提出了特征区与非特征区的迭代密度均衡算法来解决上述问题。经过算法处理的整体机匣如图 9(c)所示,它的特征数据和非特征数据都有所减少,因此该算法可以削弱数据冗余对训练效率的影响。

2) 缺失。从每个整体点云中随机选择一部分点,将 b 的 1% 的半径范围内的点删除。

3) 分布不均匀。不同形状的整体机匣特征部分的形状不一样,而且特征部分与非特征部分的体积差也不一样,经密度均衡之后,这些模型的数据密度是不同的。选择机匣装配体参与网络训练,就可以模拟数据分布不均匀。

4.3 特征分割数据集构建流程

构建特征分割数据集的过程分为以下几步:

1) 参考实际拍摄的发动机照片和实测点云,用 UG NX12.0 构建非特征和特征的参数化模板,再将两者合并为整体机匣,最后利用部件族功能产生大量尺寸形状各异的整体机匣模型。

2) 从整体机匣中分别导出非特征和特征网格,利用 meshlab 的 Poisson-disk 采样脚本文件批处理网格,生成点云。

3) 读取非特征及其对应的特征点云,运用迭代密度均衡算法,实现整体机匣特征区与非特征区的

密度均衡。局部数据密度 ρ 的定义为当前点 \mathbf{p}_i 与它的 k 个邻域点 \mathbf{p}_j ($j = 1, 2, 3, \dots, k$) 之间的平均距离:

$$\rho = \frac{1}{k} \sum_{j=1}^k |\mathbf{p}_i - \mathbf{p}_j|, \quad (3)$$

式中: $k = 10$ 。定义特征和非特征的局部数据密度分别为 ρ_f 和 ρ_{nf} , 则密度差 d 的定义式为

$$d = |\rho_{nf} - \rho_f|. \quad (4)$$

4) 根据密度均衡后的点云生成标签文件, 组合特征数据与非特征数据, 生成混合点云和混合标签。至此, 特征分割数据集(图 10)构建完成。

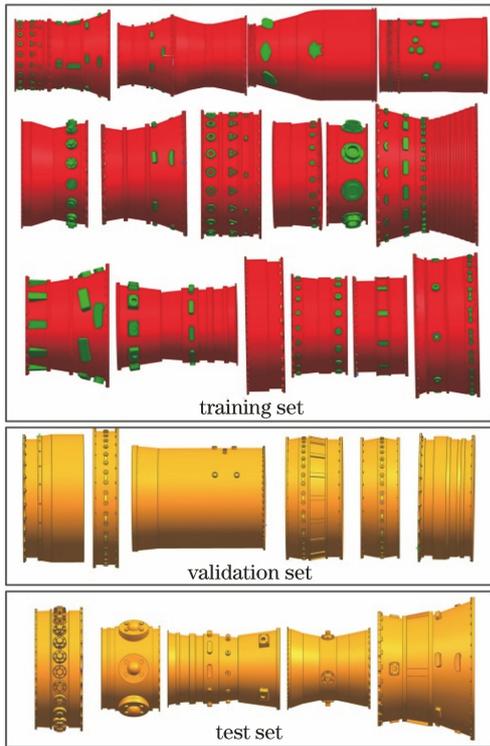


图 10 特征分割数据集

Fig. 10 Feature segmentation dataset

特征分割数据集中包括 100 个单个机匣模型和 50 个机匣装配体模型, 设定从模型中选取 patch 中心的个数分别为 400 和 800, 训练集、验证集和测试集的 patch 中心的个数之比为 8:1:1, 表 1 给出每种数据集中所包含的局部表面片个数。

表 1 每种数据集中所包含的局部表面片个数

Table 1 Number of patches contained in each data set

Data set	Operation	Patch number
Training set	$3 \times (80 \times 400 + 40 \times 800)$	192000
Validation set	$3 \times (10 \times 400 + 5 \times 800)$	24000
Test set	$3 \times (10 \times 400 + 5 \times 800)$	24000

所采用的密度均衡算法流程图如图 11 所示。

5 特征分割方法的实施细节

5.1 构建多尺度局部表面片

根据航空发动机外形点云的结构特征多、形状不规则、分布无规律、尺寸差异大、细节丰富等特点(图 12), 选择从整体点云中构造的多尺度局部表面片作为特征分割网络的输入, 这样既可以应对不同结构特征的尺寸差异, 还可以捕捉同一结构特征丰富的细节形状(图 13)。在利用 encoder unit 编码局部表面片形状结构和局部邻域信息的基础上, 特征分割网络(图 4)综合并比较从不同尺度的局部表面片中收集到的形状信息, 判断 patch 中心是否是特征点, 这有利于网络重视小尺度邻域范围内的细节形状变化, 从而确定清晰的特征分割边界。

IFPS 策略的核心是从剩余点集中寻找距离选中点集最远的那个点作为下一个选中点。在采样点个数相同的情况下, IFPS 相比随机采样可以更好地覆盖整体点云, 即使采样点个数只是整体点云的 2.5%, 这些点也充分表达了模型形状, 相反随机采样会造成采样点的局部黏结(图 14)。图 15 是 IFPS 算法流程图。

通过观察特征分割数据集中所有形状的尺寸和对应的特征尺寸, 再结合选择的局部表面片中心个数, 确定了 3 个由小到大的球邻域搜索半径值 $r_s = 0.01b$, $r_m = 0.03b$, $r_l = 0.07b$ 。

5.2 归一化局部表面片

神经网络训练时, 要求每个局部表面片中包含的点数要相等, 所以需要对球邻域搜索到的点数进行判断, 搜索到的点数超过指定数量 k 时, 随机选择 k 个邻域点作为特征分割网络的输入; 搜索到的点数小于指定数量 k 时, 补零。 $r_s = 0.01b$ 时, $k_s = 100$; $r_m = 0.03b$ 时, $k_m = 300$; $r_l = 0.07b$ 时, $k_l = 700$ 。

将邻域点坐标进行归一化。 \mathbf{p}_i 是局部表面片中心, $\mathbf{p}_{j_1}, \mathbf{p}_{j_2}, \dots, \mathbf{p}_{j_k}$ 是 \mathbf{p}_i 的 k 个邻域点, 则有

$$\mathbf{p}_{j_a} = \mathbf{p}_{j_a} - \mathbf{p}_i, \quad (5)$$

$$\mathbf{p}_{j_a} = \frac{\mathbf{p}_{j_a}}{r_1}, \quad (6)$$

式中: $a = 1, 2, \dots, k$; $r_1 = 0.07b$ 。

5.3 特征分割损失函数

通过计算预测标签和真实标签之间的距离, 得到特征分割网络的损失函数为

$$L_f(\mathbf{p}_i) = \|\tilde{f}_i - f_i\|_1, \quad (7)$$

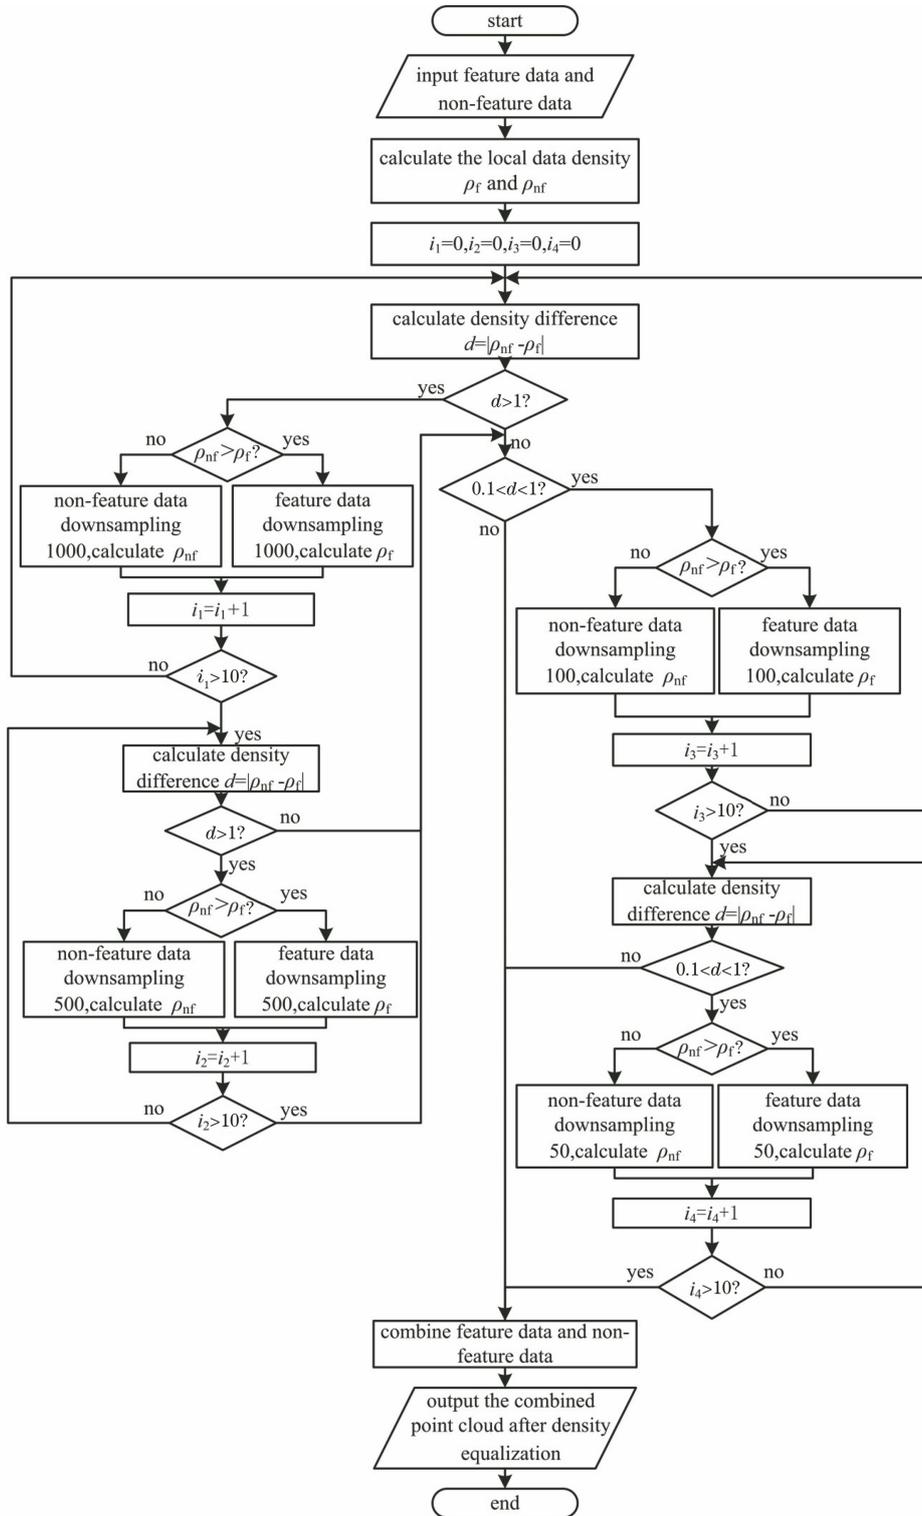


图 11 密度均衡算法流程图

Fig. 11 Flow chart of density equalization algorithm

式中： \tilde{f}_i 是特征分割网络预测 patch 中心 p_i 是特征点的概率； f_i 是 patch 中心 p_i 的真实标签。通过将特征分割网络与采用二进制的交叉熵损失函数训练好的网络模型进行对比，发现采用 $L_i(p_i)$ 可以取得更好的分割效果。

6 特征分割方法的验证与分析

为验证本文方法的有效性和优越性，采用精度和交并比 (IoU) 作为定量评估标准，进行了验证实验。航空发动机外形点云的验证与分析分成 4 部

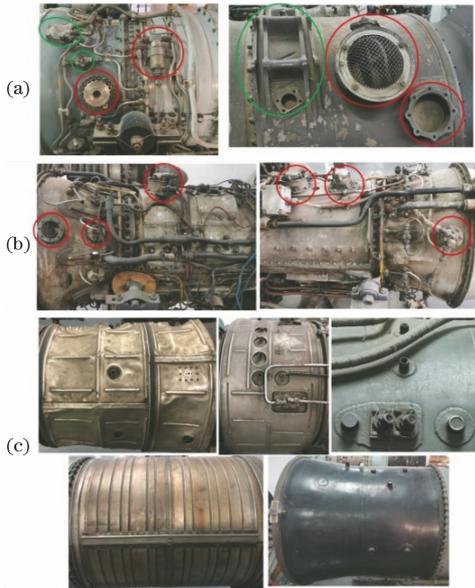


图 12 航空发动机外形点云的形状特点。(a)形状不规则；
(b)细节丰富；(c)分布无规律
Fig. 12 Shape characteristics of aero-engine profile point clouds. (a) Irregular shape; (b) rich details; (c) irregular distribution

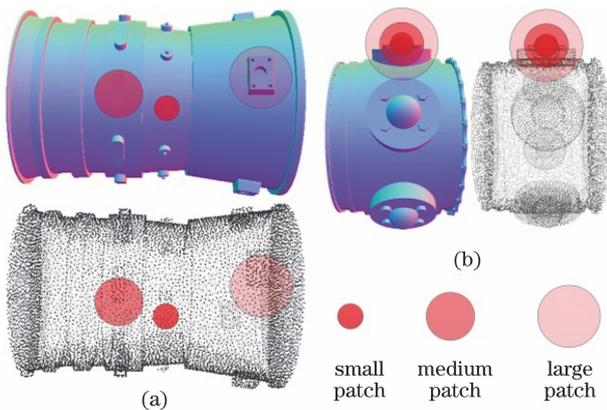


图 13 多尺度局部表面片。(a)不同结构特征的尺寸差异；(b)同一结构特征丰富的细节形状
Fig. 13 Multi-scale local patches. (a) Size difference among different structural features; (b) rich detail shapes from the same structural feature

分:1)本文方法与非网络类学习方法(K-means)、基于聚类的方法(wseg^[31])和区域生长法(region growing)的分割结果对比;2)本文网络与学习基方法 PointNet^[22]、PointNet++^[23]、DGCNN^[30]的分割结果对比;3)本文网络在不同训练集中学习后,得到不同网络模型的分割结果对比;4)本文方法处理不同噪声尺度的点云的分割结果。特征分割网络结构设计的验证与分析分成两部分:1)本文网络采用多尺度局部表面片与单尺度局部表面片作为输入的

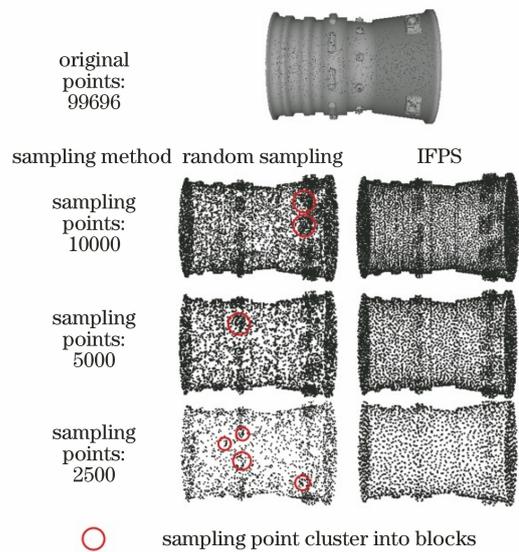


图 14 IFPS 与随机采样对比
Fig. 14 Comparison of IFPS and random sampling

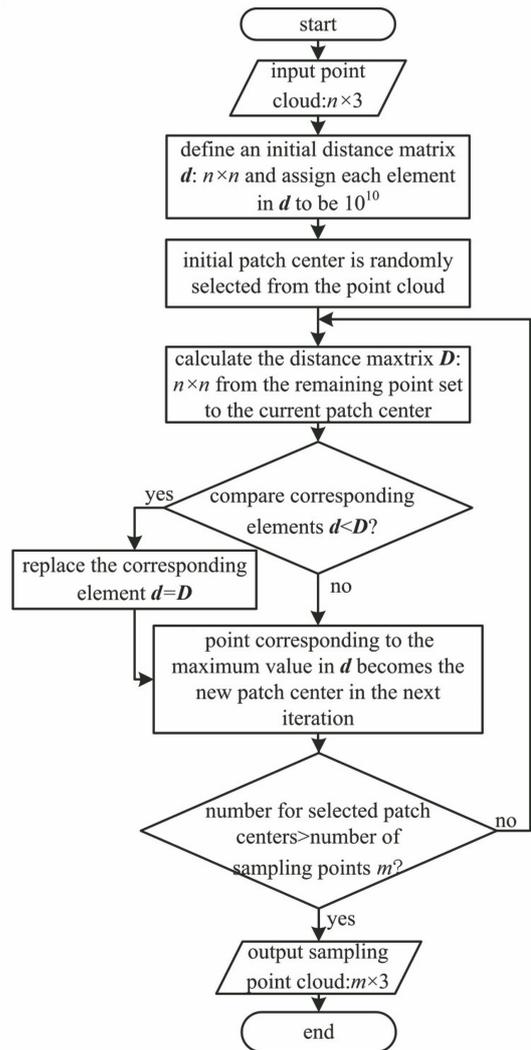


图 15 IFPS 算法流程图
Fig. 15 Flowchart of IFPS algorithm

分割结果对比;2)本文网络与采用局部表面片特征向量的编码单元组成的网络的分割结果对比。

6.1 航空发动机外形点云的验证与分析

不同方法应用于发动机外形点云的分割结果如图 16 所示, *K*-means 方法是无监督聚类的经典算法,需要设置当前形状应该被分割成的部件数量 *K* 和初始随机种子点; *wcseg* 可以避免设置每种形状的 *K* 值,但需要输入 3 个相互可见比例阈值来执行三次弱凸合并,并且需要提供计算形状直径函数的相关参数,用于执行体积一致性合并; *region*

growing 方法需要根据模型的形状特点,反复调整平滑阈值和曲率阈值。图 16 中以上三种方法的分割结果都经过了仔细的参数调整,但依旧存在不同程度的过分割和欠分割问题(黑圈标注),本文方法将训练好的特征分割网络模型直接应用于 5 种不同形状的机匣点云,不需要参数调整就可以将不同形状、不同位置、不同尺寸的凸台和加强筋都划分成特征数据,忽略由凸肩和安装边引起的机匣壳体形状变化,将其归为非特征数据。

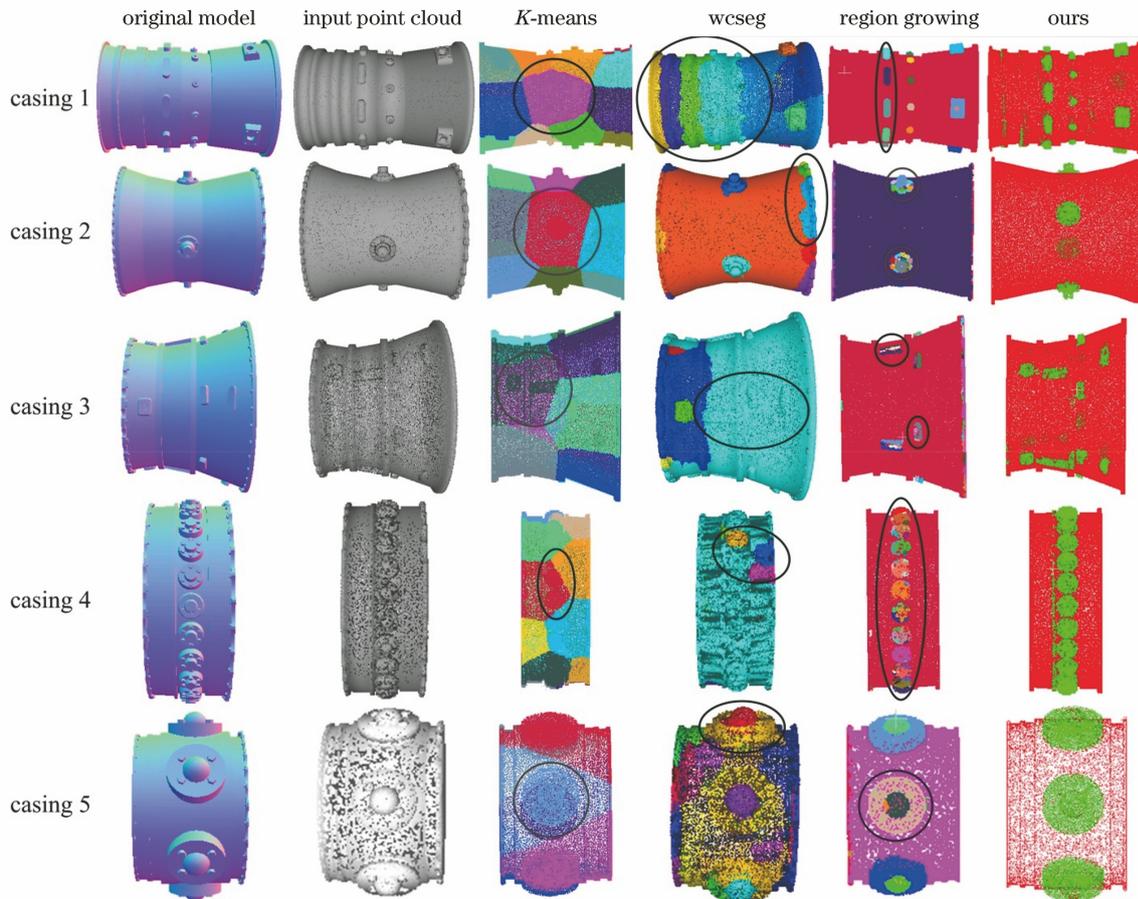


图 16 不同方法的分割结果对比

Fig. 16 Comparison of segmentation results of different methods

不同学习基方法应用于发动机外形点云的分割结果如图 17 所示,4 种网络的输入不同: *PointNet* 和 *DGCNN* 是整体点云, *PointNet++* 是局部表面片,本文方法是多尺度局部表面片。特征点在整体点云中的占比相比在局部表面片中的占比要小(表 2),导致 *PointNet* 对局部形状的学习不够充分,凸台和加强筋附近的非特征点被错误识别,当特征周围是光滑曲面(*casing 1*, *casing 2*)时,该问题不明显;当加强筋左右端面存在凸肩(*casing 3*)、凸台位于凹陷机匣壁并且相互之间距离较近(*casing 4*),凸台所处的圆柱形机匣

壁与其他机匣壁存在台阶(*casing 5*)时,特征分割的边界被扩大,此时对特征附近点的判断存在随机性。

PointNet++ 将从 *patch* 中学习到的特征向量按照距离远近,从 *patch* 中心插值传播给了 *patch* 中的其他点,导致局部表面片内部形状变化处的点被赋予了错误的特征信息,分割边界在真实结构特征的基础上被均匀扩大(*casing 1*, *casing 2*),向加强筋两侧凸肩扩散(*casing 3*),位于凹陷机匣壁的凸台两侧部分非特征点(*casing 4*)和少量台阶下的非特征点(*casing 5*)被错误识别。

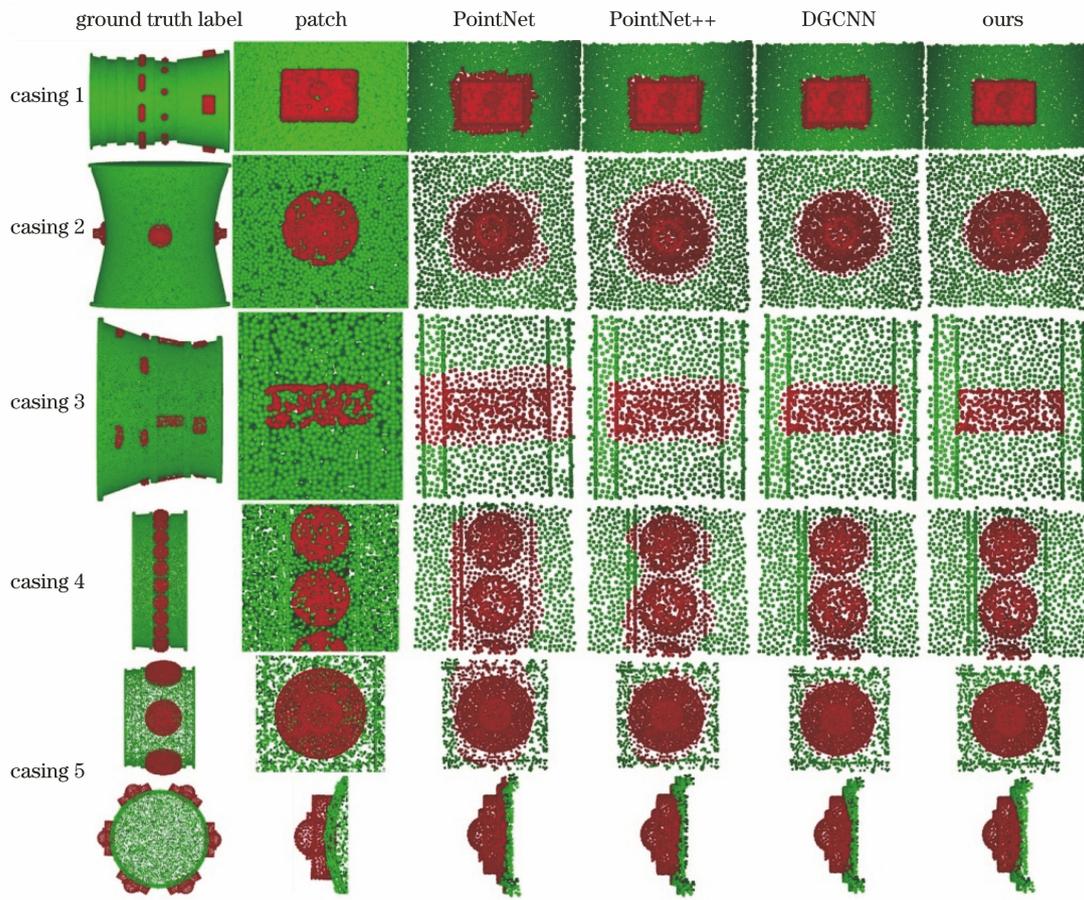


图 17 不同学习基方法的分割结果对比

Fig. 17 Comparison of segmentation results of different learning-based methods

表 2 特征点在整体点云和局部表面片中的占比

Table 2 Proportion of feature points in entire point cloud and patch

Item	Casing 1	Casing 2	Casing 3	Casing 4	Casing 5	Mean
Proportion of feature points in entire point cloud	0.1250	0.0603	0.0687	0.1895	0.3366	0.15602
Proportion of feature points in patch	0.4754	0.5400	0.2830	0.5400	0.7835	0.52438

DGCNN 分割结果相较前两种方法有了较大的改善,但在生成全局特征时只采用了最深层网络的输出结果,缺少浅层网络学习到的特征,这导致网络对整体形状变化趋势的表达不够规整[图 6(b)],凸台和加强筋周围的机匣壁被错误识别,分割边界向外小幅度扩散(casing 1, casing 2, casing 3)。另外网络缺少对小尺度细节形状的学习,导致对凸台间隔之间的部分机匣壁(casing 4)和台阶处的机匣壁(casing5)分割的错误。本文方法对整体形状变化趋势的表达是准确的[图 6(a)、(c)和(d)],并且特征分割网络通过综合比较从不同尺度的局部表面片中收集到的形状信息,判断 patch 中心是否是特征点,分割结果最符合真实标签包含的语义信息,边界清晰且质量较佳,该方法达到了本文对发动机外形点云特征分割的要求。

表 3 是本文方法应用于图 16 中外形点云的定量分析结果,5 种机匣的特征分割精度的平均值为 0.95673,分割交并比的平均值为 0.78707,这说明本文方法是有效的。表 4 是将图 17 的 4 种学习基方法应用于图 16 中外形点云的定量分析结果,将特征分割结果平均后,本文方法的精度和交并比较其他三种学习基方法都有所提升,说明本文方法是先进的。

本文网络在不同训练集中学习后,不同的网络模型分割结果对比如图 18 所示,图 18(b)和(c)说明当训练集中只包含单个机匣时,训练完的网络模型对机匣与机匣装配位置处的安装边和螺栓做出了错误的判断。当训练集中同时包含单个机匣和机匣装配体时,图 18(c)中机匣 8 的 4 个异形凸台和机匣 10 的 7 个圆柱形凸台都被清晰地识别为特征数

据,并且形状、大小、位置都是准确的,特征分割精度 达到 95.16%,实现了高精度语义分割。

表 3 本文方法的分割精度和交并比

Table 3 Segmentation accuracy and IoU of our method

Item	Casing 1	Casing 2	Casing 3	Casing 4	Casing 5	Mean
Accuracy	0.96179	0.98910	0.97056	0.97497	0.88725	0.95673
IoU	0.76218	0.82873	0.68174	0.88327	0.77940	0.78707

表 4 本文方法与其他学习基方法的分割精度和交并比平均值

Table 4 Means of segmentation accuracy and IoU of our method and other learning-based methods

Method	PointNet	PointNet++	DGCNN	Our method
Accuracy	0.87179	0.89910	0.93137	0.95673
IoU	0.53581	0.57195	0.68138	0.78707

本文方法处理不同噪声尺度的点云分割结果如图 19 所示,噪声影响了结构特征的形状特点,但是网络区分特征和非特征的模式依旧有效,所以即使是应对大尺度噪声(0.015*b* 和 0.02*b*),本文方法也取得了不错的结果,这验证了本文方法应对多种噪声尺度点云的鲁棒性。

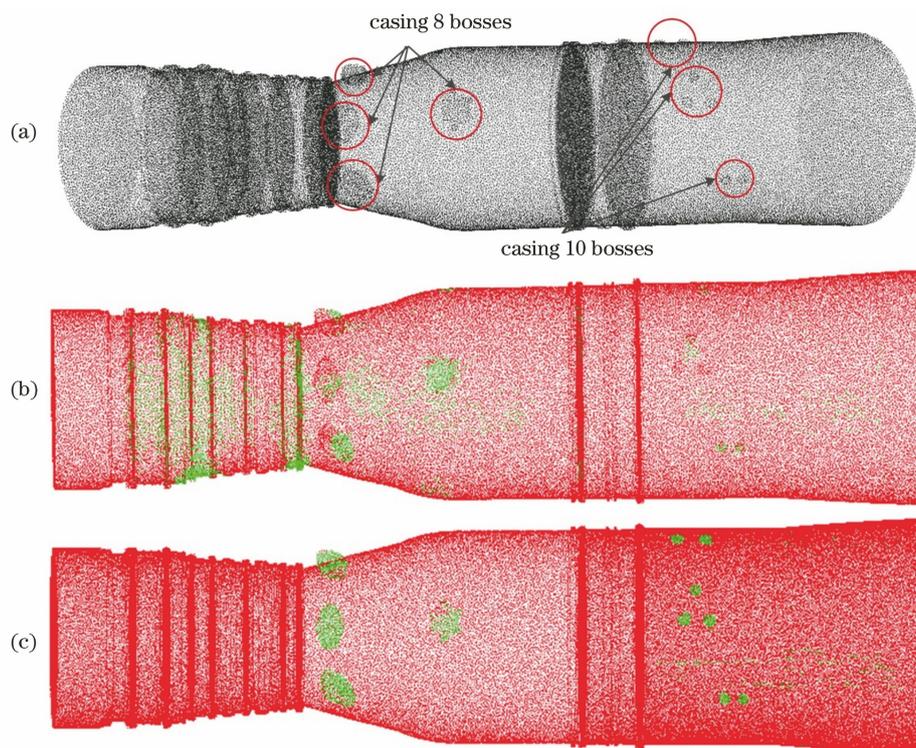


图 18 航空发动机外形点云的特征分割结果。(a)输入点云;(b)训练集只有单个机匣;(c)训练集同时有单个机匣和机匣装配体

Fig. 18 Feature segmentation results of aero-engine profile point cloud. (a) Input point cloud; (b) training set only has single casing; (c) training set has both single casing and casing assembly

6.2 特征分割网络结构设计的验证与分析

本文网络采用多尺度局部表面片与单尺度局部表面片作为输入的分割结果对比如表 5 所示,其中 single-scale 是指选择 $r=0.05b$ 作为球邻域搜索半径,构建单尺度局部表面片并将其作为图 20 中网络输入的分割结果。为了控制变量, single-scale 与 multi-scale(ours)都采用 encoder unit 收集局部形状信息,用相同的多层感知机来判断局部表面片的中心是否是特征点,并且采用相同的学习参数在同一个训练集上进行学习。

Multi-scale(ours)相比 single-scale 分割精度平均提升 6.694%。Single-scale 有效的原因是单尺度局部表面片可以覆盖一个特征的大部分形状,基于此判断其中心是否是特征点是有一定根据的,但是相比本文方法,某些细节的形状变化在单尺度局部表面片中并没有那么突出,网络在训练过程中很有可能忽略这些细节,从而做出错误的判断。

本文网络与采用局部表面片特征向量的编码单元组成的分割网络结果对比如表 6 所示。表 6 中的“Figure 21”是指将用图 21 所示的编码单元替换图 4

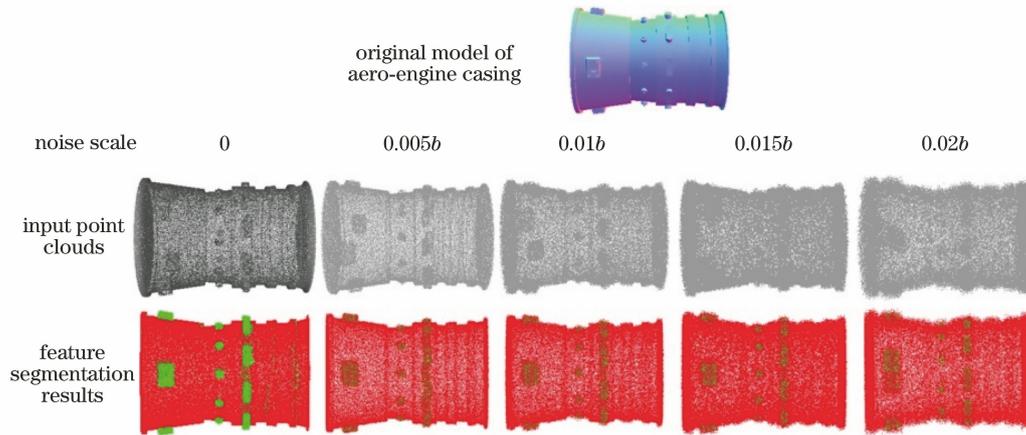


图 19 噪声点云的特征分割结果

Fig. 19 Feature segmentation results of noisy point cloud

表 5 不同输入的网络模型的分割精度对比

Table 5 Comparison of segmentation accuracy of network with different inputs

Item	Casing 1	Casing 2	Casing 3	Casing 4	Casing 5	Mean
Single-scale	0.91218	0.92173	0.90972	0.91859	0.82235	0.89691
Multi-scale (ours)	0.96179	0.98910	0.97056	0.97497	0.88725	0.95673
Improvement / %	5.440	7.310	6.690	6.140	7.890	6.694

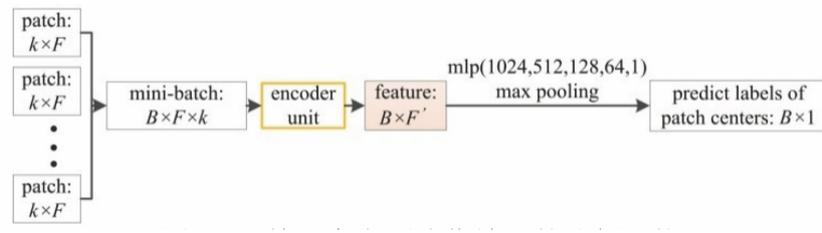


图 20 单尺度表面片作为输入的分割网络

Fig. 20 Segmentation network with single-scale surface patches as input

表 6 不同编码单元的分割精度对比

Table 6 Comparison of segmentation accuracy of different coding units

Item	Casing 1	Casing 2	Casing 3	Casing 4	Casing 5	Mean
Figure 21	0.89632	0.90719	0.88984	0.89741	0.81627	0.88141
Encoder unit (ours)	0.96179	0.98910	0.97056	0.97497	0.88725	0.95673
Improvement / %	7.300	9.030	9.070	8.640	8.700	8.548

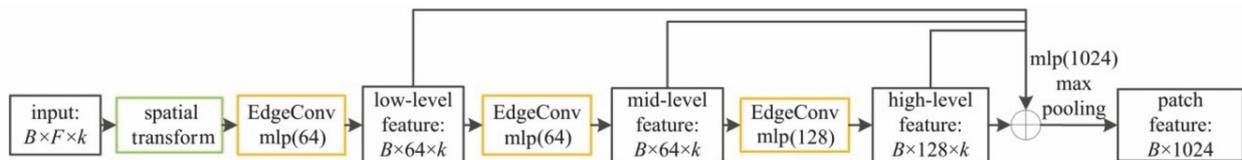


图 21 只用高级特征向量的编码单元

Fig. 21 Coding units using only high-level feature vectors

中的 encoder unit 之后组成的分割网络应用于 5 种不同形状机匣的分割结果。其中图 21 所示的编码单元相当于截取了 encoder unit 的前半部分, 直接选择局部表面片的特征向量 (patch feature: $B \times 1024$), 作为后续判断局部表面片中心是否是特征点

的依据。为了控制变量, 两种网络是采用相同的学习参数在同一个训练集上进行学习的。“encoder unit (ours)”相比“Figure 21”分割精度平均提升 8.548%。“Figure 21”所指网络有效是因为局部表面片特征向量表达了当前局部邻域内的整体形状变

化趋势,在一定程度上是可以判断局部表面片中心是否是特征点的。但是由于它缺少将浅层网络学习到的局部邻域信息(低级特征、中级特征和高级特征)和整体形状变化趋势(局部表面片特征)串联以后进一步抽象成局部表面片的形状结构,所以其结果稍逊于 encoder unit(ours)。

7 结 论

针对航空发动机外形点云的结构特征多、形状不规则、分布无规律、尺寸差异大、细节丰富等特性,提出的基于深度学习的航空发动机外形点云特征分割方法可以同时实现以下几点:1)忽略特征数据内部的形状变化,将其归为一类;2)忽略非特征数据内部的形状变化,将其归为一类;3)重视特征与非特征数据之间的形状差异,将其一分为二。所提方法解决了传统方法处理发动机外形点云出现的过分割和欠分割问题,分割精度达到 95.16%,实现了高精度语义分割,有利于重建出准确的航空发动机外形几何模型,为飞机与发动机装配协调设计提供指导。所得结论如下。

1) 构建多尺度局部表面片作为特征分割网络的输入,这样既可以应对不同结构特征的尺寸差异,又有利于捕捉到同一结构特征丰富的细节形状,该方法相比单尺度的特征分割精度提升了 6.694%。

2) 局部信息编码单元 encoder unit 结合了低级、中级和高级特征表达的局部邻域信息和局部表面片特征表达的整体形状变化趋势,抽象出了更加符合特征分割结果的高维特征空间,与采用局部表面片特征向量的编码单元相比,局部信息编码单元的特征分割精度提升了 8.548%。

3) 针对各种结构特征丰富的细节形状,利用从局部表面片中收集到的所有形状信息来判断其中心是否是特征点,其分割结果最接近真实标签并且图像边界清晰、质量佳。

参 考 文 献

- [1] Li J J, Rui Z Y, Yan C F, et al. Boundary extraction of defect hole of aero-engine blades based on double decision criteria [J]. *Aeronautical Manufacturing Technology*, 2021, 64(6): 55-62.
李景俊, 芮执元, 剡昌峰, 等. 基于双判定准则的航空发动机叶片缺陷孔洞的边界提取[J]. *航空制造技术*, 2021, 64(6): 55-62.
- [2] Zhang P C, Liu J, Yang H M, et al. Laser overlapping three-dimensional reconstruction of damaged aero engine blade [J]. *Laser & Optoelectronics Progress*, 2020, 57(16): 161504.
张鹏程, 刘瑾, 杨海马, 等. 航空发动机损伤叶片的激光交叠式三维重建[J]. *激光与光电子学进展*, 2020, 57(16): 161504.
- [3] Li Z W, Zhang P, Zhong K, et al. Development and application of AutoScan series automated 3D measuring equipment for complex parts [J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(10): 119-136.
李中伟, 张攀, 钟凯, 等. AutoScan系列复杂零件自动化三维测量装备开发与应用[J]. *航空学报*, 2021, 42(10): 119-136.
- [4] Liu Y P, Chen L J, Li M, et al. Segmentation method for point cloud of aeroengine pipelines [J]. *Acta Aeronautica et Astronautica Sinica*, 2008, 29(2): 285-291.
刘元朋, 陈良骥, 李明, 等. 航空发动机管路测量数据分割方法[J]. *航空学报*, 2008, 29(2): 285-291.
- [5] Guo Q D, Quan Y M. Depth image point cloud segmentation using spatial projection[J]. *Acta Optica Sinica*, 2020, 40(18): 1815001.
郭清达, 全燕鸣. 采用空间投影的深度图像点云分割[J]. *光学学报*, 2020, 40(18): 1815001.
- [6] Rabbani T, van den Heuvel F, Vosselman G. Segmentation of point clouds using smoothness constraint [J]. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2006, 36(5): 248-253.
- [7] Lu M, Guo Y L, Zhang J, et al. Recognizing objects in 3D point clouds with multi-scale local features[J]. *Sensors*, 2014, 14(12): 24156-24173.
- [8] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C] // 2009 IEEE International Conference on Robotics and Automation, May 12-17, 2009, Kobe, Japan. New York: IEEE Press, 2009: 3212-3217.
- [9] Wang X H, Wu L S, Chen H W, et al. Feature line extraction from a point cloud based on region clustering segmentation [J]. *Acta Optica Sinica*, 2018, 38(11): 1110001.
王晓辉, 吴禄慎, 陈华伟, 等. 基于区域聚类分割的点云特征线提取[J]. *光学学报*, 2018, 38(11): 1110001.
- [10] Wang X H, Wu L S, Chen H W, et al. Region segmentation of point cloud data based on improved particle swarm optimization fuzzy clustering [J]. *Optics and Precision Engineering*, 2017, 25(4): 563-573.
王晓辉, 吴禄慎, 陈华伟, 等. 应用改进的粒子群优化模糊聚类实现点云数据的区域分割[J]. *光学精密工程*, 2017, 25(4): 563-573.
- [11] Vo A V, Truong-Hong L, Laefer D F, et al. Octree-based region growing for point cloud segmentation

- [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 104: 88-100.
- [12] Ballard D H. Generalizing the Hough transform to detect arbitrary shapes [J]. Pattern Recognition, 1981, 13(2): 111-122.
- [13] Bolles R C, Fischler M A. A ransac-based approach to model fitting and its applications to finding cylinders in range data [C] // Proceedings of the 7th International Joint Conference on Artificial Intelligence, 1981: 637-643
- [14] Vosselman G, Gorte B G H, Sithole G, et al. Recognising structure in laser scanner point clouds [J]. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2004, 46(8): 33-38.
- [15] Wang W Q, Li Z C, Fu Y J, et al. Multi-factor segmentation of point cloud based on improved multi-rule region growing [J]. Acta Optica Sinica, 2021, 41(5): 0528001.
汪文琪, 李宗春, 付永健, 等. 基于改进多规则区域生长的点云多要素分割 [J]. 光学学报, 2021, 41(5): 0528001.
- [16] Yang X S, Pan X F, Su S J, et al. Data-driven awareness technology for space target image information [J]. Acta Optica Sinica, 2021, 41(3): 0315002.
杨小珊, 潘雪峰, 苏少杰, 等. 数据驱动的空间目标图像信息感知技术 [J]. 光学学报, 2021, 41(3): 0315002.
- [17] Chai Y J, Ma J, Liu H. Deep graph attention convolution network for point cloud semantic segmentation [J]. Laser & Optoelectronics Progress, 2021, 58(12): 1210016.
柴玉晶, 马杰, 刘红. 用于点云语义分割的深度图注意力卷积网络 [J]. 激光与光电子学进展, 2021, 58(12): 1210016.
- [18] Li H S, Wu Y J, Zheng Y P, et al. A survey of 3D data analysis and understanding based on deep learning [J]. Chinese Journal of Computers, 2020, 43(1): 41-63.
李海生, 武玉娟, 郑艳萍, 等. 基于深度学习的三维数据分析理解方法研究综述 [J]. 计算机学报, 2020, 43(1): 41-63.
- [19] Zhao L, Hu J, Liu H, et al. Deep learning based on semantic segmentation for three-dimensional object detection from point clouds [J]. Chinese Journal of Lasers, 2021, 48(17): 1710004.
赵亮, 胡杰, 刘汉, 等. 基于语义分割的深度学习激光点云三维目标检测 [J]. 中国激光, 2021, 48(17): 1710004.
- [20] Maturana D, Scherer S. VoxNet: a 3D convolutional neural network for real-time object recognition [C] // 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 28-October 2, 2015, Hamburg, Germany. New York: IEEE Press, 2015: 922-928.
- [21] Wu Z R, Song S R, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shapes [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1912-1920.
- [22] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 77-85.
- [23] Qi C R, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [EB/OL]. (2017-06-07) [2021-04-05]. <https://arxiv.org/abs/1706.02413>.
- [24] Yi L, Kim V G, Ceylan D, et al. A scalable active framework for region annotation in 3D shape collections [J]. ACM Transactions on Graphics, 2016, 35(6): 1-12.
- [25] Armeni I, Sener O, Zamir A R, et al. 3D semantic parsing of large-scale indoor spaces [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1534-1543.
- [26] Shen Y R, Feng C, Yang Y Q, et al. Neighbors do help: deeply exploiting local structures of point clouds [EB/OL]. (2017-12-19) [2021-04-05]. <https://arxiv.org/abs/1712.06760v1>.
- [27] Guerrero P, Kleiman Y, Ovsjanikov M, et al. PCPNet learning local shape properties from raw point clouds [J]. Computer Graphics Forum, 2018, 37(2): 75-85.
- [28] Rakotosaona M J, la Barbera V, Guerrero P, et al. PointCleanNet: learning to denoise and remove outliers from dense point clouds [J]. Computer Graphics Forum, 2020, 39(1): 185-203.
- [29] Gu S T, Wang L, Ma Y X, et al. Local feature description of LiDAR point cloud data based on hierarchical Mercator projection [J]. Acta Optica Sinica, 2020, 40(20): 2015001.
顾尚泰, 王玲, 马燕新, 等. 基于分层墨卡托投影的激光雷达点云数据局部特征描述 [J]. 光学学报, 2020, 40(20): 2015001.
- [30] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds [J]. ACM Transactions on Graphics, 2019, 38(5): 1-12.
- [31] Kaick O V, Fish N, Kleiman Y, et al. Shape segmentation by approximate convexity analysis [J]. ACM Transactions on Graphics, 2014, 34(1): 1-11.