

DOI: 10.19650/j.cnki.cjsi.J2513954

复杂堆叠环境下的多类相似弱纹理工件识别方法*

谢哲欣¹, 李小丽², 蒋 金³, 郑高峰¹, 张陈涛¹

(1. 厦门大学萨本栋微米纳米科学技术研究院 厦门 361102; 2. 泉州经贸学院信息技术系 泉州 362000;
3. 厦门金龙联合汽车工业有限公司 厦门 361023)

摘 要:在航空航天、汽车制造等领域,工业机器人依赖高精度的工件识别技术完成自动装配、分拣等关键任务,但在工业现场普遍存在背景复杂、工件形状与纹理相似、多个工件堆叠等情况,导致错误识别。针对上述问题,首先使用双目结构光相机采集高质量三维点云数据,并通过点云预处理有效滤除复杂环境中的背景噪声干扰;其次,提出基于改进超体素的点云过分割算法,通过引入移动最小二乘法构建局部微分几何约束对原始点云进行保形精简,优化超体素聚类过程,提升对噪声的鲁棒性并有效抑制点云粘连;设计一种基于凹凸性判断的多特征自适应超体素融合机制,综合考虑超体素聚类间的凹凸关系、几何特征相似性等多维约束,实现复杂堆叠场景中多类目标的高精度实例分割;提出基于“局部-全局”特征描述序列的支持向量机分类架构,构建多尺度特征级联描述体系,联合刻画目标的局部几何细节与全局形态特征,有效解决小样本下目标混叠导致的误分类问题。最后,搭建实验平台进行算法验证,实验结果表明,该方法显著提升了相似弱纹理工件在复杂堆叠环境下的实例分割精度及分类准确率,分割精度与识别准确率均达到 95% 以上。

关键词: 工件识别; 三维点云; 实例分割; 超体素; 特征描述

中图分类号: TH6 **文献标识码:** A **国家标准学科分类代码:** 460.50

A recognition method of multi-class similar workpieces with weak texture in complex stacking environments

Xie Zhixin¹, Li Xiaoli², Jiang Jin³, Zheng Gaofeng¹, Zhang Chentao¹

(1. Pen-Tung Sah Institute of Micro-Nano Science and Technology, Xiamen University, Xiamen 361102, China;
2. Information Technology Department, Quanzhou Vocational College of Economics and Business, Quanzhou 362000, China;
3. Xiamen King Long United Automotive Industry Co., Ltd., Xiamen 361023, China)

Abstract: In the fields of aviation, aerospace, automotive manufacturing, and beyond, industrial robots undertake vital tasks such as automated assembly and meticulous workpiece sorting, relying on precise recognition. Yet, in industrial environments, challenges like intricate backgrounds, workpieces with similar shapes and textures, and stacked arrangements often heighten the vulnerability to incorrect recognition. To surmount these challenges, a binocular structured light camera is first used to acquire of high-fidelity three-dimensional point cloud data. A preprocessing algorithm is then deployed to effectively eliminate background interference and mitigate noise within these complex settings. Subsequently, an innovative point cloud over-segmentation algorithm is proposed, which integrates the moving least squares method to construct local differential geometric constraints. This enables shape-preserving simplification on the raw point cloud, optimizes the supervoxel clustering process, enhances robustness against noise, and effectively mitigates point cloud adhesion. Further, a multi-feature adaptive supervoxel fusion mechanism based on concavity-convexity constraints is designed. This mechanism comprehensively integrates multi-dimensional constraints, including the concavity-convexity relationships between supervoxel clusters and geometric feature similarity, achieving high-precision instance segmentation of multi-class target in complex stacked scenarios. Building upon this foundation, a support vector machine classification architecture driven by "local-global" descriptor sequences is proposed. This architecture constructs a multi-scale cascaded feature description system that jointly characterizes the local geometric details and

收稿日期: 2025-04-21 Received Date: 2025-04-21

* 基金项目: 福建省科技重大专项(2024HZ022013)、福建省自然科学基金(2023J01047)项目资助

global morphological features of the targets. This approach effectively solves the misclassification problem caused by stacked targets under small-sample conditions. Finally, an industrial robot platform is devised for algorithm validation. Experimental findings showcase remarkable enhancements in instance segmentation accuracy and classification precision, particularly for similar weak-textured workpieces. The achieved workpiece segmentation accuracy and recognition precision surpass 95%, affirming the effectiveness and robustness of the proposed method.

Keywords: workpiece recognition; 3D point cloud; instance segmentation; supervoxel; feature description

0 引言

工业机器人在生产过程中扮演着关键角色,广泛应用于自动装配^[1]、分拣^[2]、零件加工^[3]等领域。然而,在航空航天、汽车等制造领域中存在着许多复杂非结构化作业场景(如动态光照干扰、工件位姿随机性及任务多样性等),传统的示教和编程方式已无法满足工业机器人应对多样化任务的需求。因此,提升机器人的环境感知能力和精准作业能力成为工业机器人发展的重要挑战。机器视觉作为机器人感知的重要手段^[4-6],为实现机器人智能化应用提供了可能性。

在机器视觉领域,目标识别是确保机器人准确理解并区分作业场景中特定目标的重要技术。基于二维图像的目标识别方法通常利用 RGB(red, green, blue)图像提供的纹理和色彩信息。在图像质量优越且包含丰富信息时,其识别效果尤为突出。如王书宇等^[7]提出一种改进几何模板匹配算法识别具有孔洞的弱纹理工件。Ji等^[8]提出一种基于流形排序的目标识别方法,通过对图像进行增强、超像素提取等过程实现在复杂环境下的目标识别。He等^[9]提出的基于区域的 Mask 卷积神经网络(Mask region-based convolutional neural network, Mask R-CNN)模型能够对目标图像进行实例分割,李秀智等^[10]通过改进的 YOLOv3(you only look once version 3)模型实现小目标物体的快速检测。然而,二维视觉方法受限于深度信息缺失,难以有效解决堆叠工件的空间位姿解耦问题。

随着三维传感器技术的不断进步,基于三维点云的目标识别方法进一步提升工业机器人环境感知能力。Gu等^[11]提出一种多尺度三维扫描方法,将三维相机安装在机械臂上,从多个角度拍摄不易准确捕捉的区域,融合信息获得目标的全景视图,可有效实现堆叠目标的三维信息重构和识别。薛珊等^[12]运用三维激光点云的中心切片提取方法,通过分析切片点云边界的圆度参数来识别工件的类型。Zhang等^[13]提出一种改进的欧几里得聚类算法以实现复杂场景下目标点云的分割,但在测试场景中缺乏多类目标堆叠的情况。针对复杂堆叠分割问题,VCCS(voxel cloud connectivity segmentation)^[14]与 LCCP(locally convex connected patches)^[15]算法通过超体

素过分割与凹凸性约束融合的策略,实现了自上而下的目标解耦,然而此类方法仍存在两方面局限:1) VCCS 依赖固定体素划分策略,对噪声敏感度高,易引发聚类中心偏移;2) LCCP 虽通过凹凸性判据优化区域合并,但其单一几何约束难以应对多类相似工件的边界模糊问题,在局部曲面突变时易产生过分割。而在分类环节,基于随机森林^[16]、支持向量机(support vector machine, SVM)^[17]、朴素贝叶斯^[18]等传统机器学习模型的手工特征描述方法(点特征直方图(point feature histogram, PFH)^[19]、快速点特征直方图(fast point feature histogram, FPFH)^[20]、视点特征直方图(viewpoint feature histogram, VFH)^[21])虽具有小样本条件下的计算效率优势,但其特征描述体系未能实现全局形态与局部几何特征的有效协同表征,在高度相似工件的特征空间分布高度重叠时分类性能显著退化。

此外,随着深度学习技术的飞速发展,许多工作将深度学习与三维数据处理相结合,以实现三维目标的高精度识别。刘永刚等^[22]提出基于自注意力机制的点云特征融合网络以提高目标检测精度。Liu等^[23]提出了 PolishNet-2D 和 PolishNet-3D 神经网络模型,分别用于二维工件检测和三维工件识别。同时,Wang等^[24]提出了一种带有随机权值的三维卷积核 ProbConv,并基于此构建了贝叶斯深度神经网络 ProbNet,以有效实现三维点云对象的识别任务。Qi等^[25]通过整合图像二维投票与点云三维投票机制的 ImVoteNet 网络,实现了对目标几何、语义和纹理特征的提取,并通过梯度混合多模态训练以提升三维目标检测性能。然而,为确保训练结果的稳定性和高精度,基于深度学习的目标识别方法极度依赖大量先验数据集,这对数据采集与标注成本提出了挑战。且在处理大规模三维数据集时,计算复杂度和资源消耗成为模型部署和实时应用的主要瓶颈。

综上所述,当前已有的目标识别方法在小样本情况下难以应对工件堆叠环境下点云粘连、以及弱纹理、高度相似工件混合所带来的分割识别难题。因此,本文提出复杂堆叠环境下的多类相似弱纹理工件识别方法,其创新性主要体现在两个方面:

1) 提出基于改进超体素的点云实例分割算法。通过移动最小二乘法构建局部微分几何约束,实现点云数据的保形精简。设计基于凹凸性判断的多特征自适应超体

素融合机制,解决了复杂堆叠环境下传统方法在点云噪声抑制与目标粘连方面的技术瓶颈。

2) 提出基于局部-全局特征描述序列的支持向量机分类架构。针对类间相似性高的堆叠工件识别难题,构建多尺度特征级联描述体系——联合局部几何细节与全局形态特征,解决了小样本条件下高度相似的弱纹理工件在特征空间混叠导致的误分类问题。




图1 算法整体框架

Fig. 1 Overall framework of the proposed algorithm

1.1 体素下采样

点云数据的复杂性和冗余性导致大量的计算开销。为了在降低计算成本的同时保持输入数据的形状特征和几何性质,采用八叉树对点云进行划分,将其分解为多个体素网格。给定体素网格大小,位于每个体素网格内的点云可通过八叉树结构,由该体素网格的质心近似表示,以实现下采样的效果。此时,质心坐标由式(1)计算可得,即:

$$\begin{cases} \bar{x} = \frac{1}{n} \sum_{(x,y,z) \in V} x \\ \bar{y} = \frac{1}{n} \sum_{(x,y,z) \in V} y \\ \bar{z} = \frac{1}{n} \sum_{(x,y,z) \in V} z \end{cases} \quad (1)$$

其中, n 为体素 V 中的点数量。

1.2 随机一致性算法去除料框

鉴于工业场景的复杂性,点云数据不仅包含目标对象的信息,还包含背景数据,如料框平面等,这些背景信息可能会对后续的目标识别造成干扰。因此,采用了随机一致性算法(random sample consensus, RANSAC)来去除料框平面。在每次迭代中, RANSAC 算法随机选择3个点构成最小点集,用于建立假设的平面模型。接着,通过式(2)计算其余点到假设平面的距离。设定距离阈值 δ_1 为2 mm,距离小于该阈值的点则被判定为内点。经过迭代, RANSAC 算法输出内点数量最多的平面模型,由此去除料框平面。

1 基于统计滤波的点云预处理

如图1所示,技术路线第1步为点云预处理。采用双目结构光三维相机获取分辨率为0.02 mm的高质量三维点云数据。针对该数据进行点云预处理,以消除料框背景干扰及噪声。

$$D = \frac{|a_1x + b_1y + c_1z + d_1|}{\sqrt{a_1^2 + b_1^2 + c_1^2}} \quad (2)$$

其中, a_1, b_1, c_1, d_1 分别代表生成假设平面的模型参数。

1.3 统计滤波去噪

统计滤波算法用来消除点云中明显的离群点。该算法首先计算每个搜索点 p_y 到其 k_y 个最近邻点的平均距离 μ_p , 并得到近邻点云的标准差 σ_p 。接着,通过给定的标准差倍数 s_{td} , 判断搜索点到其最近邻点的平均距离 $\bar{d}_p$ 是否在特定阈值范围内。如果该点符合阈值条件,即满足式(3)的要求,则将其保留。这一算法遍历整个点云,有效去除了点云中存在大尺度离群点的情况。

$$p_y = \{p_y \in P_y \mid (\mu_p - \sigma_p s_{td}) \leq \bar{d}_p \leq (\mu_p + \sigma_p s_{td})\} \quad (3)$$

预处理结果示例如图2所示。




图2 预处理效果

Fig. 2 The results of preprocessing

预处理有效减少了原始数据中背景噪声干扰,在一定程度上提升了后续实例分割的精度。然而,预处理后依然存在无法彻底去除的噪声和点云粘连现象,如图2(d)所示。

2 基于改进超体素的实例分割算法

针对上述预处理算法中无法清除的噪声点和粘连,提出了一种基于改进超体素的过分割方法,从而减少了错分割的发生。类似于超像素^[26],超体素过分割将点云划分为具有相似属性的超体素区域。再通过基于多特征及凹凸性判断的区域融合算法,将超体素融合为目标实例,提高工件实例分割的精度。

2.1 基于改进超体素的过分割算法

改进超体素过分割算法流程如图3所示。

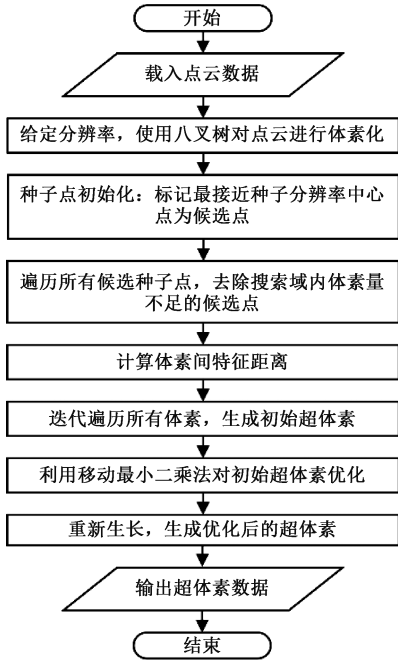


图3 改进超体素过分割算法流程

Fig. 3 Improved point cloud over-segmentation algorithm

针对给定的体素分辨率,过分割算法首先利用八叉树进行点云体素化。类似于过饱和盐溶液中的多晶核结晶过程,超体素过分割的生长过程中,所有种子点同时参与。因此在体素化后,需要选择种子点来初始化超体素。为表征体素之间的空间关系,通过体素的26个相邻体素构建邻接图。假设每个种子点在三维空间中均匀分布,选择最接近给定种子分辨率中心的体素作为种子候选。然而,需要删除那些远离其相邻体素的种子点,也就是在候选种子搜索区域内,体素数量不超过 $n_{\min}$ 的情况下,这些候选种子将被移除。过滤条件如式(4)~(6)。

$$R_{\text{search}} = \frac{1}{2} R_{\text{seed}} \quad (4)$$

$$n_{\min} = \frac{\pi R_{\text{seed}}^2}{20 R_{\text{voxel}}^2} \quad (5)$$

$$sd = \{sd \in SD \mid n > n_{\min}\} \quad (6)$$

其中, R_{search} 表示种子体素的搜索半径, R_{seed} 则是种子体素分辨率,该分辨率决定了相邻超体素之间的距离。 R_{voxel} 则代表体素尺寸大小。需要特别注意的是, R_{seed} 应远远大于 R_{voxel} ,否则种子体素将无法成功生成,可能导致错分割出现。在这个过程中, sd 代表种子体素,只有满足式(6)的种子体素才会被保留作为初始超体素,而其余周围体素不足的不合格候选将被删除。式(4)~(6)中只有 R_{seed} 与 R_{voxel} 应根据目标物尺寸相应地设置,其余参数都可根据这两个参数计算得出。

在超体素生成过程中,体素间的特征距离被用来衡量种子体素与其相邻体素之间的相似性。首先,对空间距离进行归一化处理,并限制每次聚类迭代的搜索范围。在接近另一相邻超体素的聚类中心时停止搜索,并使用 $\sqrt{3} R_{\text{seed}}$ 作为最大范围对空间特征距离进行归一化。其次,另一特征为表征表面弯曲程度的法向差。因此,三维体素数据的边界性质可以通过空间距离及法线来进行描述。特征计算的具体描述如式(7)~(9)所示。

$$D_s = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (7)$$

$$D_n = 1 - \|\mathbf{n}_i \times \mathbf{n}_j\| \quad (8)$$

$$D_{sn} = \sqrt{\frac{\lambda_d D_s^2}{3 R_{\text{seed}}^2} + \mu_d D_n^2} \quad (9)$$

其中, x, y, z 表示空间坐标, $\mathbf{n}$ 为体素法向量, D_s 和 D_n 分别代表空间距离及法向距离。 D_{sn} 为这两个特征的归一化值,而 λ_d 和 μ_d 则决定了这两个特征在计算中的权重。

迭代过程遍历所有的体素,根据体素类间的特征距离将它们融合到相应的超体素中。这一过程从较低层的体素开始逐层搜索、处理,直到遍历完所有超体素的相邻体素。此外,在更新超体素的聚类中心后,超体素会重新生长,这个过程会持续直到聚类中心稳定或达到算法设定的最大迭代次数。

由于点云噪声以及粘附,采用移动最小二乘法(moving least squares, MLS)曲面拟合来优化超体素。拟合过程如下:

首先,针对拟合范围为 r 的点 p_i ,计算其局部近似超平面 $H = \{x_m \in \mathbf{R}^3 \mid \mathbf{n}_m^T x_m = \mathbf{n}_m^T q_m\}$ 。其中, x_m 代表超平面 H 上的点, $\mathbf{R}^3$ 表示三维空间实数点集; $\mathbf{n}_m$ 是超平面的法矢; q_m 表示 p_i 的邻域点,即 p_i 以 r 为半径的 K 邻域内的点。 H 拟合的目标为最小化式(10)所示的能量函数。

$$E = \sum w(\|p_i - q_m\|) [\mathbf{n}_m^T - \mathbf{n}_m^T q_m]^2 \quad (10)$$

其中, $w(\|p_i - q_m\|)$ 为权重函数;

其次,MLS 拟合该局部区域,拟合方程如式(11)~(12)所示。

$$f(x, y) = \sum_{i=1}^6 A_i(x) I_i(x, y) = \mathbf{I}^T(x, y) \mathbf{A}(x) \quad (11)$$

$$\mathbf{I}(x, y) = [1, x, y, x^2, xy, y^2]^T \quad (12)$$

其中, x, y 代表拟合曲面方程点的空间位置, $\mathbf{I}(x, y)$ 为拟合函数的基函数, $\mathbf{I}^T(x, y)$ 为基函数的转置, $A_i(x)$ 表示 $\mathbf{I}(x, y)$ 第 i 项 $I_i(x, y)$ 的系数向量函数, $\mathbf{A}(x)$ 为系数矩阵。假设 g_i 为 p_i 到超平面 H 的正交投影, 则如式(13)所示, h_i 是 p_i 在超平面 H 上的高度。拟合过程旨在最小化目标函数 J , 其表达式如式(14)所示。

$$h_i = \|p_i - g_i\| \quad (13)$$

$$J = \sum w(\|p_i - g_i\|) [f(x, y) - h_i]^2 \quad (14)$$

由此可得移动最小二乘拟合曲面上 p_i 对应的点 P_i^* , 如式(15)所示。

$$P_i^* = g_i + f(0, 0) \mathbf{n}_m \quad (15)$$

最后, 将拟合范围内所有的点替换成其拟合曲面上的点 P_i^* , 完成拟合投影。完成 MLS 拟合后, 所有体素重新生长, 输出优化后的超体素数据。

MLS 曲面拟合的引入使得在三维相机拍摄下, 由于多个物体杂乱堆叠而导致的点云粘附现象得到消除, 同时保持了对物体形状的准确表征。效果示例如图4所示, 图4(a)、(b)与(c)、(d)分别是2组同个场景下未添加 MLS 及添加 MLS 的对比图。黑框标出了点云粘附明显去除的区域, 而整体的物体形状表征能力得到了保留。




图4 MLS 点云粘连去除效果

Fig. 4 Removal effect of MLS point cloud adhesion

MLS 通过局部加权最小二乘拟合实现对点云表面的光滑重建。已有研究表明, 当点云噪声标准差 σ 相对于

拟合半径 r 满足 $\sigma < 0.5r$ 时, MLS 能较好保持边界的几何一致性与拓扑连续性^[27]。此时, 噪声在权重函数中被快速衰减, 不会显著影响拟合中心点的平滑投影结果。在本研究中, 拟合半径设定为超体素的种子分辨率 $r = R_{\text{seed}} = 8 \text{ mm}$, 对应最大可接受噪声为 4 mm 。配合双目结构光相机的精度及预处理滤波, MLS 对该级别噪声具有良好鲁棒性。但当点云存在大量异常点或高幅度非高斯噪声时, 对离群值敏感, 可能导致拟合偏移, 进而影响超体素之间的边界精度。

MLS 具有天然的低通滤波属性, 其加权最小二乘目标函数在高曲率、边界突变或法向不连续区域可能导致一定程度的过度平滑或特征削弱, 尤其在全局点云上直接拟合时更为显著。然而本文方法并非在整体点云上应用 MLS, 而是在完成基于空间、法向与凹凸性特征的超体素聚类后, 在局部簇内进行拟合。每个超体素簇结构紧凑, 几何一致性高, 典型半径为 8 mm , 在此尺度下既能充分捕捉常规工件表面曲率变化, 又能保持拟合局部性, 避免跨区域的过度平滑。实践中 MLS 在该粒度下提升了超体素内部一致性, 为后续的特征判断与区域融合提供了稳定的几何基础。

2.2 基于多特征融合的自适应区域合并算法

完成工件实例分割需要将过分割产生的超体素合并到目标实例的点云中。超体素中有效保留目标的精确几何信息, 利用他们之间的几何特征及结构关系增加额外约束, 无需额外的训练数据集即可完成实例分割。本研究提出了一种多特征融合的距离度量, 用以判断相邻两个超体素是否应该合并。这一度量在合并算法中发挥着至关重要的作用。距离度量结合了两个关键特征: δ_c 代表相邻超体素之间的几何特征距离, 而 δ_d 则表示相邻超体素质心之间的欧氏距离。

如图5(a)所示, 假设两个相邻超体素 p_s, p_t , 质心分别为 x_s, x_t , 法向量分别为 $\mathbf{n}_s, \mathbf{n}_t$, 两质心连线方向上的单位向量 $\mathbf{C}_{st}$ 如式(16)所示。描述两相邻超体素位置关系的特征距离 δ_d , 几何关系的特征距离 δ_c 计算如式(17)~(18)所示。

$$\mathbf{C}_{st} = \frac{x_t - x_s}{\|x_t - x_s\|} \quad (16)$$

$$\delta_d(p_s, p_t) = \|x_t - x_s\| \quad (17)$$

$$\delta_c(p_s, p_t) = \frac{\|\mathbf{n}_s \times \mathbf{n}_t\| + \|\mathbf{n}_s \times \mathbf{C}_{st}\| + \|\mathbf{n}_t \times \mathbf{C}_{st}\|}{3} \quad (18)$$

结合凹凸性判断对几何特征距离进行修正, 修正后的特征距离表达如式(19)~(20)所示。

$$\delta_c(p_s, p_t) = \begin{cases} 0.5\delta_c, & \text{有效凸连接} \\ \delta_c, & \text{其他} \end{cases} \quad (19)$$

$$i_{th} = 60^\circ \{ 1 + e^{-0.25[\angle(\mathbf{n}_s, \mathbf{n}_t) - 60^\circ]} \}^{-1} \quad (20)$$

α_s, α_t 为两相邻超体素的法向量 $\mathbf{n}_s, \mathbf{n}_t$ 与其质心连线 $\mathbf{C}_{st}$ 的夹角, 如图 5(b)、(c) 所示。若 $\alpha_s < \alpha_t$ 或 $\angle(\mathbf{n}_s, \mathbf{n}_t) < 1^\circ$ 则在凹凸性判断中认为它们为凸连接。只有在两个法向量的叉积 $\mathbf{s}$ 与质心连线之间的夹角足够大时, 即 $\theta < i_{th}$, 才会认定这两个超体素的凸连接为有效凸连接。具有有效凸属性的两个超体素属于同一对象的可能性更大, 因此对其几何特征距离进行减半操作, 以增加两超体素合并几率。




图5 凹凸性判断的参数几何意义

Fig. 5 Geometric meaning of concave and convex connection

由于 δ_d, δ_c 与在数值尺度、物理含义及分布特性上差异显著, 直接进行线性叠加将导致不可比较性与不稳定性。因此, 引入线性加权函数 $T_c(\delta), T_d(\delta)$, 将原始特征归一化映射至 $[0, 1]$ 区间, 提升不同特征之间的可比性与数值平衡性, 如式 (21) 所示。

$$\delta(p_s, p_t) = T_c[\delta_c(p_s, p_t)] + T_d[\delta_d(p_s, p_t)] \quad (21)$$

考虑到不同特征在样本中的总体响应程度具有差异, 定义空间距离特征的平均值为 μ_d , 几何距离特征的平均值为 μ_c , 融合权重参数 λ_2 。为实现自适应融合, 本文引入基于均值占比的权重估计策略。转换函数 $T_c(\delta), T_d(\delta)$, 如式 (22) ~ (24) 所示。该策略可视为对不同特征在样本中响应强度的线性加权, 赋予“贡献较大”的特征更高的融合影响力。与传统固定权重方法相比, 基于均值的加权融合方式具备实现简单、响应灵敏、计算稳定等优点, 能够适应大多数工业点云场景中特征

主导关系的变化。

$$\lambda_r = \frac{\mu_c}{\mu_d + \mu_c} \quad (22)$$

$$T_c(\delta) = (1 - \lambda_r)\delta \quad (23)$$

$$T_d(\delta) = \lambda_r\delta \quad (24)$$

综上可得两相邻超体素的自适应融合多特征相似性距离 $\delta(p_s, p_t)$ 。区域合并算法具体流程如图 6 所示。分割结果示例如图 7 所示, 图 7(a) 为分割前的堆叠工件点云, 图 7(b) 为超体素过分割后效果, 图 7(c) 为区域合并后的最终分割效果。




图6 区域合并算法流程

Fig. 6 The process of region merging algorithm




图7 分割效果示例

Fig. 7 Sample of the proposed segmentation algorithm

3 基于局部-全局特征 SVM 分类算法

实例分割之后得到多种工件类别的点云实例, 接下来需要对这些目标点云进行分类以赋予语义信息。SVM 分类器将多个目标的特征向量映射到高维空间, 通过寻

找一个能够最大化类别间隔的超平面,构建分类决策函数,进而对空间中的样本点进行分类。在复杂工况下,堆叠工件具有高度相似且弱纹理的特点。针对这一问题,提取旋转图描述子作为局部特征,同时使用视点特征直方图描述子作为全局特征,并融合形成“局部-全局”特征描述,并融合形成“局部-全局”特征描述子对工件进行分类,SVM 分类算法能够在小样本情况下实现高精度的相似弱纹理工件分类识别。算法技术路线框架如图 8 所示。




图 8 分类算法技术路线框架

Fig. 8 Framework of the proposed classification algorithm

3.1 局部-全局融合特征提取

1) 关键特征点提取

为提高特征提取效率,提出一种基于关键结构显著性的自适应优化策略:通过聚焦工件局部-全局特征耦合区域的显著性点云分布,对特征搜索空间进行动态约束,从而降低冗余计算量。选取两类具有弱纹理特征的典型

工业部件——管道连接件与法兰盘进行对比分析,实物如图 9 所示。




图 9 试验用工件实物

Fig. 9 Physical specimens of workpieces

具体而言,针对管道连接件全局几何区分度高而局部表面差异性低的特点,采用基于质心坐标的全局特征关键点定位方法;对于法兰盘盘心区域局部特征显著但全局相似性强的特性,则提出局部显著性引导的圆心最近邻筛选策略。该方法通过差异化特征提取机制,实现了复杂工件分类场景下计算效率与识别精度的协同优化。如图 10 所示为法兰盘工件关键点提取结果示例。




图 10 法兰盘工件关键点提取结果示例

Fig. 10 Key point extraction results of flange workpieces

(1) 点云预处理与边界提取: 首先, 对原始法兰盘点云进行表面区域分割, 滤除背景噪声及非关键结构点云以降低计算复杂度, 如图 10(a) 所示; 随后, 为精准提取法兰盘外轮廓边界点云, 采用 Alpha Shapes 算法^[28]: 通过设定滚动圆半径参数 r_α (当 r_α 值充分大时, 该圆遍历点云边界的轨迹可收敛至实际物理轮廓), 实现边缘特征的自适应提取, 如图 10(b) 所示。

(2) 抗遮挡鲁棒圆心定位算法: 在堆叠工况下, 法兰盘常因上层工件遮挡导致外圆边界点云呈局部内凹缺损, 如图 10(b) 所示, 传统三点随机采样法易受边界残缺干扰。在边界不完整的情况下, 法兰盘外圆模型内部应包含最多的三维点云数据。基于这一特性, 提出一种基于最大内点一致性的迭代优化算法, 算法流程如图 11 所示。




图 11 圆心提取算法流程

Fig. 11 Flowchart of circle center extraction algorithm

该算法通过多次迭代找出包含最多内点的圆模型, 每次迭代时随机选取属于点云边界的 3 个样本点 p_{b1} 、 p_{b2} 和 p_{b3} , 坐标分别为 (x_{b1}, y_{b1}) 、 (x_{b2}, y_{b2}) 和 (x_{b3}, y_{b3}) , 根据这 3 点的坐标计算出圆心坐标 (x_b, y_b) 和半径 r_b , 计算公式见式 (25) ~ (28)。

$$\begin{cases} a_b = x_{b1}^2 + y_{b1}^2 \\ b_b = x_{b2}^2 + y_{b2}^2 \\ c_b = x_{b3}^2 + y_{b3}^2 \\ d_b = x_{b1}(y_{b2} - y_{b3}) - y_{b1}(x_{b2} - x_{b3}) + x_{b2}y_{b3} - x_{b3}y_{b2} \end{cases} \quad (25)$$

$$x_b = \frac{a_b(y_{b2} - y_{b3}) + b_b(y_{b3} - y_{b1}) + c_b(y_{b1} - y_{b2})}{2d_b} \quad (26)$$

$$y_b = \frac{a_b(x_{b3} - x_{b2}) + b_b(x_{b1} - x_{b3}) + c_b(x_{b2} - x_{b1})}{2d_b} \quad (27)$$

$$r_b = \sqrt{(x_b - x_{b1})^2 + (y_b - y_{b1})^2} \quad (28)$$

对于上述计算所得的圆模型, 除 3 个样本点外, 计算其余边界点 p_{bi} 到圆心的距离 d_{bi} , 若 $d_{bi} \leq r_b$ 记 p_{bi} 为圆内点, 遍历所有点后记录内点个数 n_{bi} , 首次迭代令 $N_b = 0$, 并设定最大迭代次数为 M_b 。

后续迭代过程中, 当 $n_{bi} > N_b$ 时, 更新 N_b 为 n_{bi} 。当迭代次数 $i = M_b$ 或者 $N_b \geq 700$ (此时该模型内部存在足够的内点证明其为法兰盘外圆) 时, 停止迭代并输出此时的圆模型。

(3) 关键点精确定位: 基于最优圆心坐标, 构建点云 kd-tree 空间索引结构, 快速检索圆心最近邻点作为局部特征关键点。图 10(c) 展示了完整提取结果: 圆点标记抗遮挡算法输出的鲁棒圆心, 三角标指示基于 kd-tree 检索的最近邻关键点。

2) 局部-全局耦合特征描述子构建

(1) 局部特征提取: 为克服点云局部特征旋转敏感性问题, 采用旋转图描述子 (spin image, SI) 实现三维特征至二维不变空间的映射。以法兰盘工件为例, 具体流程见后文。

如图 12 所示, 以特征关键点 p_f 为圆心, 提取半径为 r 的球形邻域点云, 基于 p_f 的单位法向量 $\vec{n}_f$ 建立圆柱坐标系: 轴向为法线方向 (直线 L), 径向为法线正交切平面 P_f 。计算球形邻域内的三维点 x_f 到 L 的距离 α_f 以及 x_f 到 P_f 的距离 β_f , 形成该点的旋转不变坐标。将 (α_f, β_f) 投影至二维网格, 生成自旋图 S_o , 映射关系 $x_f \rightarrow (\alpha_f, \beta_f)$ 中 α_f, β_f 的计算如式 (29)。




图 12 法兰盘工件局部特征示意图

Fig. 12 Illustration of local features of a flange workpiece

$$S_o(x) (S_o: \mathbf{R}^3 \rightarrow \mathbf{R}^2) \rightarrow (\alpha_f, \beta_f) = (\sqrt{\|x_f - p_f\|^2 - (\mathbf{n}_f \times (x_f - p_f))^2}, \mathbf{n}_f \times (x_f - p_f)) \quad (29)$$

在旋转图生成过程中,需优化 3 个关键参数:分辨率、尺寸及向量夹角阈值。分辨率 r_{sl} 由二维网格单元的实际物理尺寸决定,通常取三维网格边长的算术平均值作为基准值,如式(30)所示。

$$r_{sl} = \frac{1}{N_{sl}} \sum_{i=1}^N |e_i| \quad (30)$$

其中, e_i 为网格边长, N_{sl} 为总边数,并设置网格长宽相等以确保各向同性。在此基础上,旋转图尺寸(即行数与列数)需权衡描述能力与计算效率,经验性设定为 20×20 以覆盖典型局部特征区域。向量夹角阈值用于约束顶点法向量与圆柱坐标系法向量的最大偏差角,通常限制该阈值在 $60^\circ \sim 90^\circ$ 范围内(推荐值 75°),可有效抑制自遮挡导致的特征模糊。最终,基于投影点云密度分布计算各网格强度值 I ,构建具有旋转不变性的特征序列,其强度梯度变化可突出局部几何。

(2) 全局特征提取:VFH 作为一种全局特征描述子,通过融合 PFH 与 FPFH 的优势架构,显著提升了三维目标识别的鲁棒性与抗干扰性能。该方法在 FPFH 基础上进行全局扩展:一方面引入视点方差以增强尺度不变性,另一方面将局部表面形状描述扩展至完整点云集群,形成由视点方向部分与 FPFH 扩展开来的表面形状部分组成双模态统计的复合特征体系。

视点方向组成部分通过量化点云中各采样点法向量 $\mathbf{n}_{vi}$ 与视点方向向量 $\mathbf{v}_p \mathbf{p}_{vi}$ 的夹角 α_c 分布,如图 13 所示,构建表征目标-视点空间关系的统计直方图;表面形状部分则继承并拓展 FPFH 描述能力。如图 14 所示,以点 $p_{vi}(i=1,2,\dots)$ 为例,其单位法向量为 $\mathbf{n}_{vi}(i=1,2,\dots)$,法兰盘的质心标记为 c ,其单位法向量为 $\mathbf{n}_c$, α_v 为 $\mathbf{Y}_v$ 与 $\mathbf{n}_{vi}$ 的夹角, θ_v 为 $\mathbf{X}_v$ 与 $\mathbf{p}_{vi}$ 的夹角, ϕ_v 为质心 c 到点 p_{vi} 的连线与 $\mathbf{n}_c$ 的夹角。




图 14 VFH 特征-FPFH 拓展部分

Fig. 14 VFH feature-component of extended part of FPFH

其中, $\mathbf{X}_v, \mathbf{Y}_v, \mathbf{Z}_v$ 表示坐标系三轴。 $\alpha_v, \theta_v, \phi_v$ 这 3 个夹角关系形成刻画局部曲面变异度的分布直方图。

二者的协同作用不仅保留了 FPFH 对微观几何特征的敏感性,更通过全局视点约束增强了跨视角识别的一致性,其复合直方图可解析为高维特征空间中目标姿态与表面形貌的联合概率分布。

3.2 SVM 分类识别算法

通过 SI 与视点特征直方图 VFH 分别提取工件的局部几何细节与全局姿态分布特征,构建级联式局部-全局混合描述子。该描述子将 SI 的 400 维强度矩阵与 VFH 的 308 维统计直方图拼接为 708 维高维特征向量,并通过 SVM 的径向基核函数映射至再生核希尔伯特空间中,分类的关键在于找到能够划分不同类别的多个高维空间超平面。

寻找能够最大化不同类别间距离的超平面过程可被视为一个优化问题,旨在追求不同类别间的最大距离,即间隔。算法重点关注距离超平面最近的支持向量,这些支持向量决定了超平面的位置和法向量,从而直接影响分类结果。一旦确定最优决策超平面,就能将新未知工件的特征映射到高维空间中进行分类。该分类方法通过从训练数据中提取的局部-全局特征,可在小样本下精准地对新工件进行分类。

4 试验分析

为验证算法的有效性,搭建了实验平台,如图 15 所示,工业机器人为 ABB IRB 2600-20,三维相机为惟景三维 PowerScan-Pro 面结构光三维相机,工控机参数为: Intel Core i7-8750 处理器, Windows10 64 位操作系统, 8 GB 内存,使用 VS2015 VC++win64 控制台应用程序以及开源的 PCL1.9.1 点云库。为评估算法在多种场景下性能表现,实验选用 6 种不同的工件作为测试样本,包括三通管 1、三通管 2、二通管、盲板法兰、平焊法兰和对颈法兰,示例实物如图 9 所示。




图 13 VFH 特征-视点方向组成部分

Fig. 13 VFH feature-component of viewpoint direction

$$\begin{cases} \mathbf{X}_v = \mathbf{n}_c \\ \mathbf{Y}_v = \mathbf{p}_{vi} \mathbf{c} \times \mathbf{X}_v \\ \mathbf{Z}_v = \mathbf{X}_v \times \mathbf{Y}_v \end{cases} \quad (31)$$




图 15 实验平台

Fig. 15 Experimental platform

4.1 实例分割试验

1) 分割性能指标

为准确评估分割结果,对分割性能指标进行详细描述。人工标注的实例分割真实集合为 $G = \{G_1, G_2, G_3, \dots, G_n\}$, 而算法分割结果集合为 $S = \{S_1, S_2, S_3, \dots, S_n\}$, 其中 G_i, S_i 分别为某一工件实例点云集合。此外, $N_c = n$ 为人工标注真实实例个数。为评估单个分割结果精度,将分割结果与人工标注真实值对比,精度计算公式如式(32)~(33)所示。

$$TP_i = G_i \cap S_i \quad (32)$$

$$Pre_i = \frac{TP_i}{TP_i + FP_i} = \frac{TP_i}{S_i} \quad (33)$$

其中, TP_i 表示单个目标工件点云集合 G_i 被准确分割的点数,为 G_i 与 S_i 重叠部分点数的计算结果。 FP_i 则表示算法错误判定为目标工件的点数总和。

由于存在噪声及其他原因,人工标注结果也可能存在少量误差。因此将精度超过 95% 的工件视为成功分割的工件。定义 N_T 为成功分割工件,则识别率计算如式(34)所示。

$$Reg = \frac{N_T}{N_c} \quad (34)$$

2) 关键参数影响分析

为评估关键参数对实例分割性能的影响,以三通管典型工件场景为例,人工标注图如图 16(a) 所示,围绕 3 个核心参数开展了影响分析:点云体素分辨率 R_{voxel} 、超体素种子分辨率 R_{seed} 与融合判定阈值 τ 。采用控制变量法,固定其他参数,仅改变单个参数,记录其对应的分割精度、识别率、运行时间以及其他关联指标,分析各参数对系统性能的影响,并探讨其在实际工业应用中的推荐取值区间与鲁棒性。

(1) 点云体素分辨率 R_{voxel}

体素分辨率 R_{voxel} 直接影响点云下采样程度、表面形




图 16 关键参数影响分析结果

Fig. 16 Result of key parameter effect analysis

状估计精度及空间数据量。本研究测试了 $R_{\text{voxel}} = 1.5, 2.0, 3.0, 4.0, 5.0$ mm 这 5 组参数,在三通管工件上对分割结果进行评估,结果如图 16(b) 所示。从结果可见,随着分辨率增大,运行时间显著下降,同时分割精度与识别率也随之下降。当 $R_{\text{voxel}} = 2.0$ mm 时,系统在保持较高识别准确率的同时具备良好计算效率。

(2) 超体素种子分辨率 R_{seed}

种子分辨率 R_{seed} 控制超体素的初始聚类粒度,进而影响区域划分的细致程度与处理复杂度。在固定体素分辨率为 2 mm 条件下,测试 $R_{\text{seed}} = 4, 6, 8, 10, 12$ mm,结果如图 16(c) 所示。随着种子分辨率增大,超体素聚类数量减少,运行效率提升,但分割精度及识别率开始下降。分析表明,当 $R_{\text{seed}} = 7 \sim 9$ mm 时,系统整体性能最佳,识别率与精度稳定,且聚类结构规整、误差低,适合工业场景中常见的中等复杂度工件。

(3) 融合判定阈值 τ

融合阈值 τ 是控制区域是否合并的关键参数,直接影响分割粒度与实例识别边界。设置 $\tau = 0.15, 0.2, 0.25, 0.3, 0.35, 0.4, 0.45$ 进行实验,结果如图 16(d) 所示。结果显示,较小阈值下区域倾向保持分离,识别率提升但精度下降,即分割出的工件不具结构完整性;较大阈值下合并倾向增强,易产生误合并。综合评估, $\tau = 0.2 \sim 0.4$ 时在分割质量与结构连贯性之间取得良好平衡。

3) 数据精简性验证

为验证所提出的实例分割算法在数据精简方面的技术优势,与同等分辨率下的 VCCS 算法进行 10 组对比实验。图 17 通过量化展示了 2 种算法在 10 次重复实验中过分割处理前后的数据规模变化及对应的简化率。实验数据显示,本算法在全部测试案例中持续保持 65% 以上的数据简化率,相较基准方法展现出显著优势。这一优势源于本方法创新的超体素优化机制:首先通过移动 MLS 曲面拟合对初始超体素簇进行几何正则化处理,有效消除离散噪声点和粘连区域。对比分析表明,传统 VCCS 算法受限于刚性体素划分策略,并未表现出数据精简的效果,严重制约后续处理效率。




图 17 不同场景下过分割数据精简效果
Fig. 17 The simplifying example results of our over-segmentation algorithm

4) 分割性能验证

为验证本文实例分割算法的精确性,与传统 Euclidean 算法^[29]以及同质质自上而下的 VCCS+LCCP 算法在不同工件上分别进行 10 次试验。实验中,针对不同工件设置不同阈值以得到最佳分割精度。为确保对比结果的公正性,在所有算法中使用了统一的体素分辨率和搜索半径。详细的实验参数如表 1 所示。

表 1 实例分割参数设置

Table 1 Instance segmentation parameters			
参数	Euclidean	VCCS+LCCP	本文算法
体素分辨率 (搜索范围)/mm	2	2	2
种子分辨率/mm	—	8	8
阈值 (最高精度)	—	10°/5° /20°/5°	0.25/0.25/ 0.35/0.25

注:阈值对应的工件为三通管 1、三通管 2、二通管和混合法兰。

不同分割方法在工件实例分割中的性能评估如表 2 所示。为系统性评估自下而上分割架构中各组件的贡献,设计了交叉验证实验,重点分析 VCCS 方法结合本文区域合并算法与本文过分割算法结合 LCCP 方法的协同效应。实验数据表明,本研究所提出的方法在 5 类典型工件(三通管 1、三通管 2、二通管、混合管道及混合法兰)上取得显著性能提升,平均分割精度分别达到 0.988、0.984、0.988、0.990 和 0.989,对应的实例识别率分别为 93.6%、97.5%、98.5%、95.2% 和 94.5%。相较于基准方法,本算法在精度指标上平均提升 14.3 个百分点。

表 2 实例分割性能对比

Table 2 Comparison of instance segmentation performance

工件类型	方法	平均分割精度	平均识别率/%
三通管 1	Euclidean	0.835	70.5
	VCCS+LCCP	0.943	83.1
	VCCS+our merging	0.915	78.0
	Our over-segmentation+LCCP	0.934	86.8
	本文算法	0.988	93.6
三通管 2	Euclidean	0.796	64.3
	VCCS+LCCP	0.899	82.8
	VCCS+our merging	0.906	83.6
	Our over-segmentation+LCCP	0.917	85.5
	本文算法	0.984	97.5
双通管	Euclidean	0.908	81.3
	VCCS+LCCP	0.928	84.5
	VCCS+our merging	0.926	84.0
	Our over-segmentation+LCCP	0.974	94.25
	本文算法	0.988	95.8
混合管道	Euclidean	0.897	67.5
	VCCS+LCCP	0.906	79.2
	VCCS+our merging	0.921	84.9
	Our over-segmentation+LCCP	0.947	86.2
	本文算法	0.983	95.2
混合法兰	Euclidean	0.780	50.6
	VCCS+LCCP	0.954	90.4
	VCCS+our merging	0.937	86.8
	Our over-segmentation+LCCP	0.964	92.8
	本文算法	0.989	94.5

对比实验中,逐点式欧氏聚类算法表现欠佳,其在 5 类工件上的平均精度分别为 0.835、0.796、0.908、0.897 和 0.780,对应识别率仅达 70.5%、64.3%、81.3%、

67.5%和50.6%。这主要源于该算法在复杂拓扑结构下的空间特征表征能力不足。相比之下,采用过分割-区域融合策略的自顶向下方法展现出中等性能,其平均精度分别为0.943、0.899、0.928、0.906和0.954,识别率分布在79.2%~90.4%。交叉验证结果进一步揭示,提出的改进型超体素过分割算法通过优化点云聚类拟合机制,有效缓解了传统方法中普遍存在的点云粘连现象,使过

分割区域的边界贴合度得到提升。
图18展示了4类典型工件的实例分割可视化结果,其中矩形框标注区域表征误分割案例。可视化分析表明,其他方法普遍存在分割不足和过度分割现象,导致点云拓扑结构断裂等问题。本方法在堆叠工件场景中展现出卓越的分割鲁棒性,特别是在复杂空间交叠区域较传统方法保持更完整的几何特征,分割完整性较其他方法有明显提升。




图 18 不同工件分割可视化结果
Fig. 18 Visualization results of different workpieces segmentation

4.2 分类识别试验

为验证本算法在复杂工业部件分类中的有效性,选取具有高度几何相似性的管道与法兰盘工件构建对比实验体系。实验设计采用经典特征描述子作为基准参照组,包括:局部协方差描述子组合^[16](涵盖曲率变化率、平面度指数、发散度指数、线性度指数及各向异性系数等六维特征)、FPFH、局部旋转图 SI^[30]、VFH、聚类视点特征直方图(clustered viewpoint feature histogram,CVFH)^[31]以及基于正交投影的局部特征描述子(triple orthogonal local depth images,TOLDI)^[32]。

表3实验数据表明,本算法展现出优越的分类性能。在管道工件分类任务中达到95.8%的准确率,较VFH和CVFH两个全局特征描述子分别仅提升0.7和1.4个百分点。该结果印证了管道工件的分类决策主要依赖于全局几何特征,其局部特征类间差异性不足以形成有效判别依据。值得注意的是,在法兰工件分类任务中,本算

表 3 分类识别性能对比		
Table 3 Comparison of classification performance		
工件类型	特征	分类准确率/%
混合三通管	协方差描述子组合	53.8
	FPFH	52.4
	Spin_Image	37.1
	VFH	95.1
	CVFH	94.4
	TOLDI	76.2
	本文算法	95.8
混合法兰	协方差描述子组合	70.2
	FPFH	78.5
	Spin_Image	92.6
	VFH	93.2
	CVFH	90.9
	TOLDI	91.7
	本文算法	97.5

法准确率达到 97.5%,较其他描述子呈现显著性优势。这归因于法兰类工件在全局特征空间具有强相似性,而本算法通过构建多尺度局部特征提取机制,有效捕获法兰关键部位的几何异质性,实现局部-全局特征的自适应融合。

表 4 揭示了不同工件类别的特异性识别规律。从分类子项分析可见:VFH 描述子在三通管 1 与对颈法兰的区分度达 92.3%;SI 描述子凭借旋转不变性优势,在盲板法兰与平焊法兰分类任务中表现最优;值得关注的是,在处理三通管 2、双通管和对颈法兰时,本文提出的描述子相较于其他方法具有更强的特异性和分类能力。实验结果表明,本算法在保持全局形状表征能力同时,通过增强局部细节特征的贡献权重,有效解决了工业部件分类中的类内差异难题。

表 4 不同工件识别准确率

Table 4 The recognition accuracy of different workpieces						
特征	三通管 1	三通管 2	双通管	盲板 法兰	平焊 法兰	对颈 法兰
协方差描述子组合	0.447	0.915	0.265	0.659	0.862	0.646
FPFH	0.936	0.277	0.367	1	0.138	0.979
Spin_Image	0.340	0.723	0.061	1	1	0.813
VFH	1	0.936	0.918	0.932	0.828	1
CVFH	0.979	0.936	0.918	1	0.862	0.854
TOLDI	0.553	0.894	0.837	0.841	0.931	0.979
本文算法	0.957	0.957	0.959	0.955	0.966	1

5 结 论

针对工业现场普遍存在的复杂工况环境,包括背景干扰严重、工件几何形貌相似性高、表面纹理特征弱及多目标堆叠遮挡等,上述多重挑战容易导致特征混淆、邻域边界模糊及误匹配现象,致使传统识别方法在复杂堆叠场景下出现显著性能退化。为此,提出改进超体素聚类的点云实例分割算法,通过引入移动最小二乘法拟合区域生长策略以及凹凸性判断与多特征自适应区域融合策略,有效克服点云噪声干扰与目标间粘连现象,实现点云数据的高效精简与精确分割;构建基于多尺度特征描述子序列的 SVM 分类模型。通过建立局部几何细节与全局形态特征的级联描述向量,提高工件描述的准确性,尤其在面对形貌相似且堆叠的弱纹理工件时,能够更细致地捕获工件的关键特征,增强分类识别的准确率;建立多维度性能验证体系。在包含 6 类典型工件的测试集上,

本方法展现出优异的综合性能:不同工件的实例分割精度均高于 0.98,分类准确率高于 95.8%,有效提高了相似弱纹理工件的实例分割精度及分类准确率,充分验证了本方法在工业场景下的工程适用性。

参考文献

[1] SU J H, LIU CH K, LI R. Robot precision assembly combining with passive and active compliant motions[J]. IEEE Transactions on Industrial Electronics. 2022, 69(8): 8157-8167.

[2] JIN G M, YU X K, CHEN Y Q, et al. SCARA + system: Bin picking system of revolution-symmetry objects[J]. IEEE Transactions on Industrial Electronics. 2024, 71(9): 10976-10986.

[3] 李特,葛宇航,艾靖超,等. 锥形薄壁筒内轮式加工机器人自适应运动控制[J]. 仪器仪表学报, 2023, 44(5): 90-99.

LI T, GE Y H, AI J CH, et al. Adaptive motion control of wheeled machining robot in conical thin-walled cylinder[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 90-99.

[4] 王斌,吴丹,盖宇航. 面向机器人精密装配的高精度圆片位姿视觉检测[J]. 机械工程学报, 2023, 59(8): 50-59.

WANG B, WU D, GAI Y H. High-precision wafer pose visual detection for robot precise assembly[J]. Journal of Mechanical Engineering, 2023, 59(8): 50-59.

[5] 胡志强,吴一全. 基于机器视觉的芯片缺陷检测研究进展[J]. 仪器仪表学报, 2024, 45(7): 1-26.

HU ZH Q, WU Y Q. Research progress in chip defect detection based on machine vision[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 1-26.

[6] 徐哲壮,黄平,陈丹,等. 融合机器视觉与邻近度估计的相似工业设备识别策略研究[J]. 仪器仪表学报, 2023, 44(1): 283-290.

XU ZH ZH, HUANG P, CHEN D, et al. Research on similar industrial devices recognition strategy based on machine vision and proximity estimation[J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 283-290.

[7] 王书宇,田建艳,蔡文站,等. 基于孔特征的弱纹理堆叠工件识别[J]. 计算机工程与应用, 2022, 58(3): 282-288.

WANG SH Y, TIAN J Y, CAI W ZH, et al. Recognition of stacked texture-less workpieces based on hole features[J]. Computer Engineering and Applications, 2022, 58(3): 282-288.

- [8] JI W, GAO X X, XU B, et al. Target recognition method of green pepper harvesting robot based on manifold ranking [J]. Computers and Electronics in Agriculture, 2020, 177: 105663.
- [9] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. 2017 IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [10] 李秀智, 李家豪, 张祥银, 等. 基于深度学习的机器人最优抓取姿态检测方法 [J]. 仪器仪表学报, 2020, 41(5): 108-117.
- LI X ZH, LI J H, ZHANG X Y, et al. Detection method of robot optimal grasp posture based on deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 108-117.
- [11] GU D J, ZHU K, SHAO Y CH, et al. 3D scanning and multiple point cloud registration with active view complementation for panoramically imaging large-scale plants [C]. 12th International Conference on Intelligent Robotics and Applications, 2019: 329-341.
- [12] 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 SH, LYU N F, SHEN Y Y, et al. Identification method for machine workpiece based on laser 3D point cloud [J]. Infrared and Laser Engineering, 2019, 48(4): 169-176.
- [13] ZHANG ZH, ZHANG N S, WANG AI M. Improved Euclidean clustering and segmentation algorithm for workpiece identification [C]. 2024 IEEE International Conference on Mechatronics and Automation, 2024: 74-78.
- [14] PAPON J, ABRAMOV A, SCHOELER M, et al. Voxel cloud connectivity segmentation-supervoxels for point clouds [C]. 2013 IEEE Conference on Computer Vision and Pattern Recognition, 2013: 2027-2034.
- [15] STEIN S C, SCHOELER M, PAPON J, et al. Object partitioning using local convexity [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 304-311.
- [16] 马振宇, 庞勇, 李增元, 等. 地基激光雷达森林近地面点云精细分类与倒木提取 [J]. 遥感学报, 2019, 23(4): 743-755.
- MA ZH Y, PANG Y, LI Z Y, et al. Fine classification of near-ground point cloud based on terrestrial laser scanning and detection of forest fallen wood [J]. Journal of Remote Sensing, 2019, 23(4): 743-755.
- [17] 郭明玮, 赵宇宙, 项俊平, 等. 基于支持向量机的目标检测算法综述 [J]. 控制与决策, 2014, 29(2): 193-200.
- GUO M W, ZHAO Y ZH, XIANG J P, et al. Review of object detection methods based on SVM [J]. Control and Decision, 2014, 29(2): 193-200.
- [18] 董立岩, 苑森森, 刘光远, 等. 基于贝叶斯分类器的图像分类 [J]. 吉林大学学报 (理学版), 2007, 45(2): 249-253.
- DONG L Y, YUAN S M, LIU G Y, et al. Image classification based on Bayesian classifier [J]. Journal of Jilin University (Science Edition), 2007, 45(2): 249-253.
- [19] RUSU R B, BLODOW N, MARTON Z C, et al. Aligning point cloud views using persistent feature histograms [C]. 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2008: 3384-3391.
- [20] RUSU R B, BLODOW N, BEETZ M, et al. Fast point feature histograms (FPFH) for 3D registration [C]. 2009 IEEE International Conference on Robotics and Automation, 2009: 3212-3217.
- [21] RUSU R B, BRADSKI G, THIBAU R, et al. Fast 3D recognition and pose using the viewpoint feature histogram [C]. 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2010: 2155-2162.
- [22] 刘永刚, 于丰宁, 章新杰, 等. 基于激光点云与图像融合的 3D 目标检测研究 [J]. 机械工程学报, 2022, 58(24): 289-299.
- LIU Y G, YU F N, ZHANG X J, et al. Research on 3D object detection based on laser point cloud and image fusion [J]. Journal of Mechanical Engineering, 2022, 58(24): 289-299.
- [23] LIU F Q, WANG Z Y. PolishNet-2D and PolishNet-3D: Deep learning-based workpiece recognition [J]. IEEE Access, 2019, 7: 127042-127054.
- [24] WANG X Y, ZHANG K, LI H Y, et al. ProbNet: Bayesian deep neural network for point cloud analysis [J]. Computers & Graphics, 2022, 104: 106-115.
- [25] QI C R, CHEN X L, LITANY O, et al. ImVoteNet: Boosting 3D object detection in point clouds with image votes [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 4404-4413.
- [26] ZHAO L, LI ZH H, MEN CH G, et al. Superpixels extracted via region fusion with boundary constraint [J]. Journal of Visual Communication and Image Representation, 2020, 66: 102743.
- [27] ÖZTIRELI A C, GUENNEBAUD G, GROSS M. Feature

preserving point set surfaces based on non-linear kernel regression[J]. Computer Graphics Forum, 2009, 28(2): 493-501.

- [28] EDELSBRUNNER H, KIRKPATRICK D G, SEIDEL R. On the shape of a set of points in the plane[J]. IEEE Transactions on Information Theory, 1983, 29(4): 551-559.
- [29] SANSONI G, BELLANDI P, LEONI F, et al. Opto-ranger: A 3D pattern matching method for bin picking applications[J]. Optics and Lasers in Engineering, 2014, 54: 222-231.
- [30] JOHNSON A E, HEBERT M. Using spin images for efficient object recognition in cluttered 3D scenes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(5): 433-449.
- [31] ALDOMA A, VINCZE M, BLODOW N, et al. CAD-model recognition and 6DOF pose estimation using 3D cues[C]. 2011 IEEE International Conference on Computer Vision Workshops, 2011: 585-592.
- [32] YANG J Q, ZHANG Q, XIAO Y, et al. TOLDI: An effective and robust approach for 3D local shape description[J]. Pattern Recognition, 2017, 65: 175-187.

作者简介



谢哲欣, 2019年于大连海事大学获得学士学位, 2023年于厦门大学获得硕士学位, 现为厦门大学博士研究生, 主要研究方向为三维视觉。

E-mail: zhixinxie@stu.xmu.edu.cn

Xie Zhixin received her B. Sc. degree from Dalian Maritime University in 2019, received her M. Sc. degree from Xiamen University in 2023. Now she is a doctoral candidate in Xiamen University. Her main research interest includes 3D version.



李小丽, 2005年四川农业大学获得学士学位, 2008年于华侨大学获得硕士学位, 现为泉州经贸学院教授, 主要研究方向为人工智能、大数据与计算机视觉。

E-mail: 121550357@qq.com

Li Xiaoli received her B. Sc. degree from Sichuan Agricultural University in 2005 and her M. Sc. degree from Huaqiao University in 2008. She is currently a professor at Quanzhou Vocational College of Economics and Business. Her main research areas include artificial intelligence, big data, and computer vision.



蒋金, 2013年于淮南师范学院获得学士学位, 2021年于清华大学获得博士学位, 现为厦门金龙联合汽车工业有限公司高级工程师, 主要研究方向为智能网联新能源汽车。

E-mail: johnking61@163.com

Jiang Jin received his B. Sc. degree from Huainan Normal University in 2013 and his Ph. D. degree from Tsinghua University in 2021. He is currently a senior engineer at Xiamen King Long United Automotive Industry Co., Ltd. His main research focus is intelligent connected new energy vehicles.



张陈涛(通信作者), 2010年于哈尔滨工业大学获得学士学位, 2017年于厦门大学获得博士学位, 现为厦门大学助理教授, 主要研究方向为机器视觉与环境感知、智能机器人。

E-mail: zhangct@xmu.edu.cn

Zhang Chentao (Corresponding author) received his B. Sc. degree from Harbin Institute of Technology in 2010, received his Ph. D. degree from Xiamen University in 2017. Now he is an assistant professor at Xiamen University. His main research interests include machine vision and environmental perception, and intelligent robot.