

复杂环境下异形多目标识别与点云获取算法

陈明猷¹, 唐昀超², 邹湘军^{1*}, 黄矿裕¹, 冯文贤², 张坡¹

¹华南农业大学工程学院, 广东 广州 510642;

²广东工业大学土木与交通工程学院, 广东 广州 510006

摘要 研究了复杂环境下不同形状物体的快速识别、定位以及表面检测,旨在满足智能机器在线作业时对复杂环境中的目标进行同步性抓取以及表面检测等需求,讨论了异形物体的多目标快速识别、定位、立体匹配及点云后处理算法。首先,基于稳健主成分分析识别出场景中的新增目标,再运用改进 k 均值聚类对各目标进行图像定位。然后,通过支持向量机筛选出感兴趣区域,并借助外极线约束进行一维搜索获取双目图像中的待匹配区域,快速获得局部三维点云。最后,进行特定的点云去噪处理以减小误差。实验结果表明,相比于传统方法,本文算法有效缩短了程序运行时间,并有效抑制了由复杂背景引起的各种噪声,提高了在复杂环境下获取点云的精度和自适应性,是一种稳健、有效、快速的三维点云获取算法。

关键词 机器视觉; 点云获取; 低秩数据恢复; 立体匹配; 识别; 定位

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP55.111505

Multi-Shaped Targets Recognition and Point Clouds Acquisition Algorithm in Complex Environment

Chen Mingyou¹, Tang Yunchao², Zou Xiangjun^{1*}, Huang Kuangyu¹,
Feng Wenxian², Zhang Po¹

¹ Collage of Engineering, South China Agricultural University, Guangzhou, Guangdong 510642, China;

² School of Civil and Transportation Engineering, Guangdong University of Technology,
Guangzhou, Guangdong 510006, China

Abstract Fast recognizing, positioning and surface detection of multi-shaped objects in complex environment are studied to satisfy the requirement of smart machines, which is expected to grab the objects or inspect surface deflection in complex environment in real time. Fast recognition, positioning, stereo matching and post-processing algorithm of point clouds are discussed. At first, new targets in the scene are recognized by robust principal component analysis, and the image location of the targets is accurately acquired by improved k -means clustering algorithm. Then, the region of interest is screened out by support vector machine, and one-dimensional searching is carried out by epipolar restriction to obtain the regions to be matched in binocular images, and local three-dimensional point clouds are quickly obtained. Finally, special denoising operation of point clouds is conducted to reduce the error. The experiment results indicate that the proposed algorithm effectively reduces the running time of the process and effectively reduces all the noises caused by complex backgrounds, and improves the accuracy and adaptability of point clouds acquisition in complex environment, and it is a robust, effective and fast algorithm for three-dimensional point clouds acquisition.

Key words machine vision; point cloud acquisition; low-rank data recovery; stereo matching; recognition; positioning

OCIS codes 150.0155; 100.3010; 150.3040; 040.1880

收稿日期: 2018-04-20; 修回日期: 2018-05-20; 录用日期: 2018-05-29

基金项目: 国家自然科学基金(51578162)、广东省科技计划项目(2016B090912005)、国家重点科技计划(2017YFD0700100)

* E-mail: xjzou1@163.com

111505-1

1 引言

用机器视觉对特定目标进行三维定位与表面点云获取,指导机器人进行抓取作业或进一步获取表面几何细节信息是智能机器人的关键技术。在实际作业环境中,目标往往置于较为复杂的车间里,呈现杂乱分布、光照不均匀、背景错综复杂等多种情况。鉴于工业生产环境的复杂性,为最大限度满足工业生产的智能化要求,对各种复杂环境下的目标识别、定位及点云算法进行研究是必要的。常见的方法是使用多种图像处理算法及技术对复杂因素进行抑制,实现目标定位,然后通过一系列的点云处理方法得到目标精确表面。

复杂环境下识别、定位与高精度三维点云获取至今依旧具有较大的挑战性。文献[1]探讨了基于边缘梯度的模板匹配算法与最小二乘法,实现了目标的精确位姿定位,但目标所在环境复杂程度欠高;文献[2]结合二次阈值分割与方向倒角匹配法,实现了复杂背景下工件的识别,但其中涉及的大津法一定程度上依赖于背景与目标的灰度差异,当背景与目标灰度近似时,较难达到理想结果;文献[3]研究了改进迭代最近点(ICP)算法实现了亚像素级零件图像配准,但配准初值一定程度上依赖于模板匹配,有可能陷入局部最优解;文献[4]将灰度空间转换与AdaBoost学习算法结合,较好地将目标区域同其他杂质区域分开,但是算法只对特定的颜色模型敏感;文献[5]根据背景与目标的频率差别建立数学模型,成功分离出复杂背景下的弱小目标,但场景的复杂度未达到工业复杂场景的标准。对于复杂工业环境、杂乱无序目标的应用研究,目前还缺乏较成熟的精确算法和应用案例。

鉴于已有研究对复杂环境目标识别定位与重构技术的局限性^[6-7],本文在已有研究的基础上进一步提高工作环境的复杂度,以期实现一种更为实用、稳定、高效的算法与应用。本研究针对的是复杂环境下对多目标的识别定位以及进一步获取三维点云的情形。所指的复杂环境,即背景杂乱、背景与目标物体颜色相近、非线性光照、目标堆叠等;所指的多目标,即对象为两个或以上特定的不同类型目标。在此研究背景下,基于稳健主成分分析(RPCA)、支持向量机(SVM)、改进 k 均值(k -means)聚类,结合双目图像外极线约束,提出一种自适应的复杂环境匹配区域定位与快速低噪三维点云获取方法。实验结果证明,本文算法可以在复杂度较高的场景下可靠

地识别出多个新增目标,为立体匹配提供区域建议,大大缩小了其搜索范围,提高了点云获取效率。同时,该算法可以有效降低复杂环境下的误匹配发生率,有效去除噪声,充分体现出其在复杂工业环境下稳健、高效、精确的特点。

2 原理与方法

本研究的创新在于融合了RPCA、改进 k -means聚类、SVM分类三种机器学习方法,解决了复杂环境下高度杂乱无序、堆叠、非线性光照的多目标识别与定位问题,解决了点云获取的精度与速度的矛盾,同时将双目立体视觉原理与最小二乘法、统计学原理相结合,实现了高效精确的点云去噪,为自动化与检测提供可能性。

该算法被分解为目标识别定位与点云去噪两个部分。首先,获取去畸变与经过外极线校准后的双目图像对,训练左图像场景的RPCA模型,提取复杂场景中的新增目标。然后,进行粗略的形态学处理,得到各目标近似质心作为 k -means聚类的初值,通过聚类获取目标中心的精确图像坐标,实现对各个目标区域的图像坐标定位。在此基础上,使用SVM分类器剔除非感兴趣目标。以左图像目标为模板,沿着外极线对右图像进行搜索,获取右图像对应目标的位置,进而完成局部立体匹配,得到局部视差图与三维点云。最后,通过坐标变换及统计学方法实现点云去噪,得到特定目标的精确三维点云。本文算法的流程如图1所示。

2.1 基于RPCA的新增目标识别

在复杂背景下,目标与背景的区分度相对较低。同时,背景中复杂的灰度分布也对目标的特征筛选造成了较大的干扰。由于上述原因,传统的基于边缘梯度信息、图像增强、特征点筛选等方法对目标的识别分割效果不太明显,这些问题在相关文献中已有提及^[8-10]。因此,为了准确可靠地识别出复杂环境中的目标,需要一种稳健的、自适应的方法。

2.1.1 RPCA

RPCA是由Candès等^[11]提出的一种去噪方法,应用比较广泛。RPCA通过构造数学模型并进行优化计算,将低秩的无污染图像 \mathbf{A} 和高秩的噪声成分 \mathbf{E} 从受噪声污染的原图像 \mathbf{D} 中分离,实现自适应去噪。RPCA优化模型如下:

$$\min_{\mathbf{A}, \mathbf{E}} \text{rank}(\mathbf{A}) + \lambda \|\mathbf{E}\|_0, \text{ s.t. } \mathbf{D} = \mathbf{A} + \mathbf{E}, \quad (1)$$

式中 $\text{rank}(\cdot)$ 是秩函数符号, λ 是正式化项, $\|\cdot\|_0$ 为0范数符号。

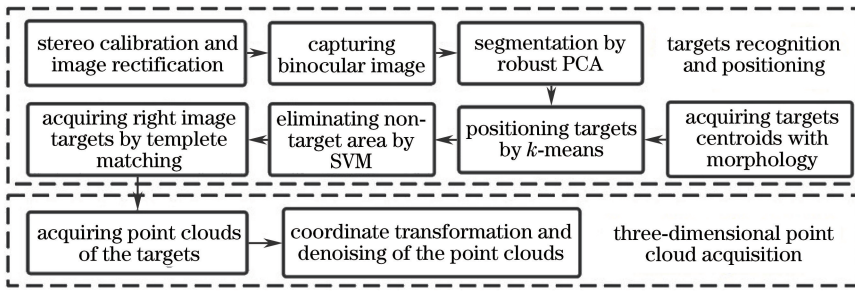


图1 算法流程

Fig. 1 Workflow of algorithm

(1)式是一个非凸优化问题。文献[11]表明,核范数是对应秩函数的最优凸替代。使用1范数近似替代0范数,则上述问题可以松弛为

$$\min_{\mathbf{A}, \mathbf{E}} \|\mathbf{A}\|_* + \lambda \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{D} = \mathbf{A} + \mathbf{E}, \quad (2)$$

式中 $\|\cdot\|_*$ 和 $\|\cdot\|_1$ 分别为核范数符号和1范数符号。

对于(2)式所述问题,已经有多种解决方法,其中增广拉格朗日乘子法(ALM)具有简单、高效、精度高的优点^[12]。

2.1.2 ALM 的实现

ALM是基础数学问题,已有相关文献^[13]对其进行了介绍。在RPCA的优化模型中,对应的ALM模型为

$$\min_{\mathbf{A}, \mathbf{E}} \|\mathbf{A}\|_* + \lambda \|\mathbf{E}\|_1 + \text{tr}[\mathbf{Y}^T(\mathbf{D} - \mathbf{A} - \mathbf{E})] + \frac{\mu}{2} \|\mathbf{D} - \mathbf{A} - \mathbf{E}\|_F^2, \quad (3)$$

式中 \mathbf{Y} 为拉格朗日算子, μ 为惩罚系数, $\text{tr}(\cdot)$ 为迹运算符, $\|\cdot\|_F$ 为F范数符号。对于这个双变量优化问题,可以通过交叉迭代法^[14]求解,即

$$\begin{cases} \mathbf{A} := \arg\min_{\mathbf{A}} \|\mathbf{A}\|_* + \text{tr}[\mathbf{Y}^T(\mathbf{D} - \mathbf{A} - \mathbf{E})] + \frac{\mu}{2} \|\mathbf{D} - \mathbf{A} - \mathbf{E}\|_F^2 \\ \mathbf{E} := \arg\min_{\mathbf{E}} \lambda \|\mathbf{E}\|_1 + \text{tr}[\mathbf{Y}^T(\mathbf{D} - \mathbf{A} - \mathbf{E})] + \frac{\mu}{2} \|\mathbf{D} - \mathbf{A} - \mathbf{E}\|_F^2 \end{cases}, \quad (4)$$



图2 RPCA 样本训练示意图。(a)场景样本之一;(b)目标样本;(c)训练过程

Fig. 2 Schematic of RPCA scene sample training. (a) One of the scene samples; (b) target sample; (c) training process

式中 $:=$ 为赋值符号。设定 \mathbf{A} 、 \mathbf{E} 初值以及收敛条件后,通过(4)式进行迭代,可获得最优值 $\hat{\mathbf{A}}$ 和 $\hat{\mathbf{E}}$ 。本文在C++环境下通过ALM实现了(2)式的优化计算。

2.1.3 RPCA 的具体实现

新进入摄像机视场的目标会为原场景引入明显的高秩成分,通过求解RPCA优化模型,新增目标会被视为噪声而归于高秩矩阵 \mathbf{E} 中。本文正是利用此特点,将新增目标视为原训练集的噪声部分,将其从复杂的背景以及非线性光中分离出来。

RPCA的训练过程属于直推式学习,计算量较大,其训练样本均经过体积压缩。训练样本包括场景样本和目标样本。训练前,拍摄多张不含有目标的固定工作场景图片。随着拍摄时刻的不同,每张场景图片间存在不同的高斯噪声、亮度变化、视场微小偏移等,这些差异提高了算法对随机因素干扰的适应性,将其压缩后得到的场景样本之一如图2(a)所示。目标进入场景后,采集该时刻含有新增目标的图片并进行压缩,得到目标样本,如图2(b)所示。采集完毕后,将多张场景样本与该张目标样本进行直推式训练,可直接将目标样本中的目标和背景分离,如图2(c)所示。

RPCA在复杂环境下的分割效果如图3所示,其中图3(a)为待分割的原图像(即目标样本压缩前的图像),分割出的目标如图3(b)所示。




图3 RPCA 分割效果示意图。

(a)待分割原图像;(b)高秩噪声(目标)

Fig. 3 Schematic diagram of RPCA in image segmentation. (a) Image to be segmented; (b) high-rank noises (targets)

2.2 改进 k -means 聚类

目标轮廓的质心可以作为其图像定位中心。但是,RPCA 提取出的目标经过自适应阈值分割后可能出现与目标主体相离且位于目标附近的噪声,影响质心坐标的精度,如图 4(a)所示,噪声用绿色圈标记。形态学处理方法^[15]可以有效去除上述噪声,




图4 形态学处理效果。(a)对高秩噪声的自适应阈值分割;(b)形态学处理;(c)原图对应位置的像素

Fig. 4 Effect of morphology operation. (a) Adaptive thresholding segmentation to high-rank noises;

(b) morphology operation; (c) corresponding pixels in original image

当聚类中心的初值取值严重偏离真实聚类中心时,算法的聚类效果不能让人满意。形态学处理可以为 k -means 聚类提供较为接近全局最优解的聚类初值,并且提供准确的簇数。本文通过开运算处理得到目标轮廓的近似质心,并将其作为 k -means 聚类的初值,即

$$\mu_{i0} = \frac{\sum_{x \in X_{ROI}} x}{S(C_i)}, \quad (6)$$

式中 $S(C_i)$ 为形态学处理所得第 i 个目标区域的像素面积, $\{x | x \in X_{ROI}\}$ 为第 i 个目标区域内的点的像素坐标集合。

图 5 为聚类过程示意图,用蓝色圈起的点为形态学处理获取的目标近似质心。由于原目标二值图像未经形态学处理,失真程度相对较低,故将形态学处理获得的近似质心作为聚类中心的初值,在原目标二值图上进行聚类,经过多次迭代得到精确的图像定位中心及对应的外包矩形框。

2.3 基于 SVM 的目标区域筛选

本文通过训练线性 SVM 模型,对上述目标区

避免两个轮廓相连而被误识别为一个轮廓,但也可能会导致目标图像失真,如图 4(b)、4(c)所示。因此考虑将形态学处理与 k -means 聚类相结合,将基于形态学处理获得的近似质心作为聚类中心的初值,同时为聚类提供正确的目标数,通过多次迭代,得到各目标中心精确的像素坐标。

k -means 聚类通过迭代计算获得最佳的聚类中心和对应样本点的类别。对于样本集 $D = \{x_1, x_2, \dots, x_m\}$, 给定 k 个聚类中心的初值 $\mu = \{\mu_1, \mu_2, \dots, \mu_k\}$, k -means 聚类算法的目标是最小化以下平方误差:

$$E = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|_2^2, \quad (5)$$

式中 C_i 为第 i 个聚类中心 μ_i 对应的类别, $\{x | x \in C_i\}$ 表示样本集 D 中到聚类中心 μ_i 的距离比到其他聚类中心的距离要小的元素的集合。

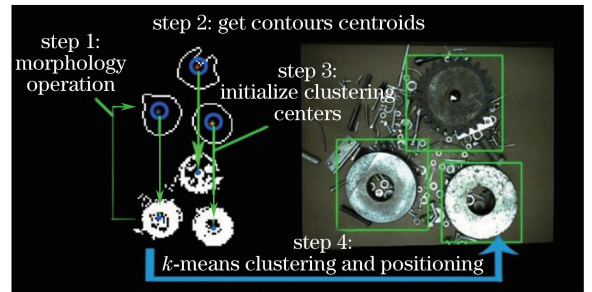


图5 改进 k -means 聚类过程

Fig. 5 Improved k -means clustering process

域进行分类,剔除不感兴趣的目标,降低后期三维点云获取的计算量。线性 SVM 的优化目标是逻辑回归优化目标的线性近似,即

$$\min_{\theta} C \sum_{i=1}^m [y^{(i)} \text{cost}_1(\theta^T x^{(i)}) + (1 - y^{(i)}) \cdot \text{cost}_0(\theta^T x^{(i)})] + \frac{1}{2} \sum_{j=1}^n \theta_j^2, \quad (7)$$

其中,

$$\begin{cases} \text{cost}_1(\theta^T x^{(i)}) = -\ln h_{\theta}[x^{(i)}] \\ \text{cost}_0(\theta^T x^{(i)}) = -\ln\{1 - h_{\theta}[x^{(i)}]\} \end{cases}, \quad (8)$$

式中 C 为常数项, m 为样本数, n 为特征数, θ^T 为特征组成的向量, $(x^{(i)}, y^{(i)})$ 为第 i 个样本, $h_{\theta}(x)$ 为 SVM 的假设模型, 即

$$h_{\theta}(x) = \begin{cases} 1, & \theta^T x \geq 1 \\ 0, & \theta^T x < -1 \end{cases} \quad (9)$$




图 6 SVM 分类示意图。(a)输入目标区域;(b)输出标签为 1 的目标;(c)输出标签为 0 的目标;(d)训练与分类过程
Fig. 6 Schematic of SVM classification. (a) Input regions; (b) output targets with label 1; (c) output targets with label 0; (d) training and classification progress

场景所有新增目标的图像定位如图 6(a)所示。SVM 分类前,定义齿轮工件的标签为 1,圆环工件的标签为 0。图 6(b)为当感兴趣对象标签为 1 时的目标筛选结果,图 6(c)为当感兴趣对象标签为 0 时的目标筛选结果。识别目标不限于两类,多类 SVM 分类同理。

2.4 基于外极线约束的右图像目标定位

理论上,只需对左、右图像都进行一次上述图像识别、定位操作,即可得到双目图像中对应目标的区域。但是,重复进行两次操作意味着计算量加倍,并非首选的方法。本文充分利用双目图像对的外极线约束,在获取目标在左图像的位置后,以目标外包矩形框内的图像为模板,沿着外极线在右图像中进行一维搜索,得到右图像对应目标位置,完成右图像对应目标的图像坐标定位。这种搜索方式的计算量远小于重新进行一次前文所述操作的计算量。

2.4.1 沿外极线的目标区域搜索

在双目视觉系统中,左右成像平面上的对应物理点 P_l, P_r 满足外极线约束,直观表现为左图像某个点在右图像的对应点必在其对应的极线上。进行外极线校准后的左右双目图像对,匹配像素点的行号相同,如图 7 所示。

如图 8 所示,在正确定位出左图像感兴趣目标 A 所在区域后,以其为模板,从左上角 P_l 起,沿着外极线水平搜索,最终在右图像 P_r 处得到最佳匹配值,完成右图像 A 目标的定位。图 9(a)和(b)分别为图 6(b)和(c)对应的右图像目标定位结果。代价聚合方式为归一化相关系数法^[16]。

2.4.2 视差修正

目标区域在左右图像的位置确定后,即可进行局

训练时,先离线采集多张目标的正样本和负样本。将样本训练获得模型参数后,对各目标区域进行分类,得到其对应的标签,剔除不感兴趣目标。SVM 分类流程如图 6 所示。




图 7 外极线校准示意图
Fig. 7 Schematic of epipolar line rectification




图 8 模板沿着外极线搜索匹配点
Fig. 8 Template searching matching point through epipolar line




图 9 右图像中的目标区域定位。(a) 1 号目标;(b) 0 号目标
Fig. 9 Positioning of right image objects. (a) Targets labeled 1; (b) targets labeled 0

部立体匹配。由于局部立体匹配使用的是感兴趣区域而非原图,改变了匹配点原来的横坐标值,故需对视差图的灰度值进行修正,才能得到正确的视差图。

新旧坐标的关系如图 10 所示。其中 o'_l 和 o'_r 分别为目标所在区域的左上点, 其在原像素坐标系 $x_l o_l y_l$ 和 $x_r o_r y_r$ 上的横坐标分别为 x_{l0} 和 x_{r0} 。对于工件上的一点 Q_0 , 在左右图像上的投影分别为 q_l 和 q_r , q_l 在坐标系 $x'_l o'_l y'_l$ 上的横坐标为 x'_{l1} , 在坐标系 $x_l o_l y_l$ 上的横坐标为 x_{l1} , q_r 在坐标系 $x'_r o'_r y'_r$ 上




图 10 新旧坐标关系

Fig. 10 Relationship between new and old coordinates

2.5 点云去噪算法

视差图经过进一步处理, 可以获得目标三维点云。三角测量法是由视差图计算三维点云的一种经典、有效的方法^[17], 其获取三维点云的计算方式为

$$[X \ Y \ Z \ W]^T = Q [u \ v \ d \ 1]^T, \quad (11)$$

式中 Q 为 4×4 的重投影矩阵, $[u \ v]^T$ 为视差图中某个点的像素坐标, d 为该像素点在视差图中的灰度值, $[X \ Y \ Z \ W]^T$ 为所获取的三维点云的齐次坐标。

三角测量法所获取的结构三维点云中, 会不可避免地存在噪声。根据噪声的分布特征, 本文采用几何学与统计学^[18]方法进行抑制, 先通过改进直通滤波去除占比较大的目标底部固定噪声, 然后先后通过半径滤波、统计滤波实现大尺度点云噪声的去除。

2.5.1 固定噪声的去除

工业环境中的杂乱背景会产生大量与主体结构无关的固定点云。对于这些固定点云的去除, 直通滤波是最简单的方法^[19]。然而, 直通滤波的坐标截断阈值往往难以界定, 本研究通过坐标变换实现了改进的直通滤波, 解决了传统直通滤波阈值选择困难的问题。

如图 11 所示, 借助高精度标定板, 建立与工件底部连结的笛卡尔坐标系(下称标定板坐标系), 求取标定板坐标系到左摄像机坐标系的转换矩阵 ${}^C_B T$, 并将基于摄像机坐标系的点云转移到标定板坐标系上。作此坐标变换的意义在于, 变换后的目标点云与工作台表面的杂物点云将同时落在 $X_B O Y_B$ 面上, 原来在摄像机坐标系上关于 X_C, Y_C, Z_C 的三维截断阈值选择问题转化为标定板坐标系上关于 Z_B 的一维截断阈值选择问题。

的横坐标为 x'_{r1} , 在坐标系 $x_r o_r y_r$ 上的横坐标为 x_{r1} 。设 d 为 q_l 和 q_r 的真实视差, d' 为 q_l 和 q_r 在像素坐标系 $x'_l o'_l y'_l$ 和 $x'_r o'_r y'_r$ 下求得的视差, 则

$$d = x_{l1} - x_{r1}, d' = x'_{l1} - x'_{r1},$$

$$x_{l1} = x_{l0} + x'_{l1}, x_{r1} = x_{r0} + x'_{r1}, \quad (10)$$

联立以上各式可得 $d = d' + (x_{l0} - x_{r0})$ 。




图 11 改进直通滤波原理示意图

Fig. 11 Illustration of advanced pass through denoising

坐标变换关系 ${}^C_B T$ 的求取是通过最小二乘法实现的。设标定板共有 m 个圆靶图案, 各圆心在标定板坐标系下的坐标分别为 ${}^B P_j (j = 1, 2, \dots, m)$ 。在左摄像机坐标系下的坐标为 ${}^C P_j$, 则有

$${}^C P_j = {}^C_B T {}^B P_j, \quad (12)$$

代入各个 j 值, 并将 m 条等式合并成矩阵形式, 记为 $[{}^C P_1 \ {}^C P_2 \ \dots \ {}^C P_m] = P_C$, $[{}^B P_1 \ {}^B P_2 \ \dots \ {}^B P_m] = P_B$, 则根据(12)式可得

$$P_C = {}^C_B T P_B, \quad (13)$$

考虑对于任意矩阵 A , AA^T 为对称方阵, 将(13)式等号两边同时右乘 P_B^T , 得到

$${}^C_B T = P_C P_B^T (P_B P_B^T)^{-1}, \quad (14)$$

由此获得了 ${}^C_B T$ 矩阵。设被测物体经过三角测量法共生成 s 个相对于左摄像机坐标系的三维点, 第 k 个三维点在标定板坐标系下的坐标为 ${}^B P^{(k)} (k = 1, 2, \dots, s)$, 在该摄像机坐标系下的坐标为 ${}^C P^{(k)}$, 有

$$\begin{cases} {}^B P^{(k)} = {}^C_B T^{-1} \cdot {}^C P^{(k)} \\ {}^B P^{(k)} = [P_C P_B^T (P_B P_B^T)^{-1}]^{-1} \cdot {}^C P^{(k)}, \end{cases} \quad (15)$$

代入 \mathbf{P}_C 与 \mathbf{P}_B 的值以及所有的 k , 得到相对于标定板坐标系的目标三维点云:

$$\begin{bmatrix} {}^B\mathbf{P}^{(1)} \\ {}^B\mathbf{P}^{(2)} \\ \vdots \\ {}^B\mathbf{P}^{(s)} \end{bmatrix} = \left\{ \begin{bmatrix} {}^C\mathbf{P}_1 \\ {}^C\mathbf{P}_2 \\ \vdots \\ {}^C\mathbf{P}_m \end{bmatrix}^T \begin{bmatrix} {}^B\mathbf{P}_1 \\ {}^B\mathbf{P}_2 \\ \vdots \\ {}^B\mathbf{P}_m \end{bmatrix} \begin{bmatrix} {}^B\mathbf{P}_1 \\ {}^B\mathbf{P}_2 \\ \vdots \\ {}^B\mathbf{P}_m \end{bmatrix}^T \begin{bmatrix} {}^B\mathbf{P}_1 \\ {}^B\mathbf{P}_2 \\ \vdots \\ {}^B\mathbf{P}_m \end{bmatrix} \right\}^{-1} \begin{bmatrix} {}^C\mathbf{P}^{(1)} \\ {}^C\mathbf{P}^{(2)} \\ \vdots \\ {}^C\mathbf{P}^{(s)} \end{bmatrix}. \quad (16)$$

坐标变换完成后, 采用平面 $X_B = T$ 截取点云, 其下方的所有点均被直通滤波器定义为噪声, 即

$$\{(X_B, Y_B, Z_B) \mid X_B \in \mathbf{R}, Y_B \in \mathbf{R}, Z_B \in (-\infty, T)\}, \quad (17)$$

式中 T 为点云在 Z_B 方向的截断阈值, 应满足小于目标高度 T_0 且大于最高底部杂物高度 h_e 。在作业开始前, 可以提前使用人工测量或者查阅生产文件的方式大致得到 T_0 , 从而进一步确定 T 。由于双目相机只获取目标的上表面点云, 所以这种噪声定义方式基本不会造成目标点云的误删, T 可以尽可能选取接近 T_0 的值。本文中, 取 $T = 2/3T_0$ 。在不同的工作环境下, 可以进一步适当增大 T , 直到去除全部底部固定杂物点云。

2.5.2 大尺度噪声的去除

除了目标底部固定噪声外, 还存在相当一部分随机噪声与远端误匹配点, 这些噪声以较大尺度从三维空间的不同方向散布于点云模型主体结构之外, 可以通过统计滤波去除。

对于点云 $\{\mathbf{P}\}$ 中的任意点 \mathbf{P}_i , 求取其到最近邻的 k_n 个点的距离均值

$$d_i = \frac{\sum_{\mathbf{P}_j \in \{\mathbf{P}_{k_i}\}} \|\mathbf{P}_i - \mathbf{P}_j\|}{k_n}, \quad (18)$$

式中 $\{\mathbf{P}_{k_i}\}$ 表示点 \mathbf{P}_i 的最近邻 k_n 个点组成的集合。设点云 $\{\mathbf{P}\}$ 的元素个数为 C_N , 当 $i = 1, 2, \dots, C_N$ 时, (18) 式得到对应的距离均值集合为 $\{\mathbf{X}\}$ 。

理论上, \mathbf{X} 服从正态分布 $N(\mu, \sigma)$ 。由于正态分布的 3σ 区间是整个样本空间的较好逼近, 选择其子区间作为判断点云是否属于噪声的标准区间, 即

$$[\mu - \alpha \cdot \sigma, \mu + \alpha \cdot \sigma]. \quad (19)$$

距离均值落在标准区间外的点被统计滤波器视为噪声, 其中 $\alpha < 3$ 用于确定标准区间的宽度。在本文的所有实验例中, 取 $k_n = 40, \alpha = 2.5$ 均能取得较

好的统计滤波效果。在其他应用场合下, 可作相应调整。

另一方面, 考虑到统计滤波的计算量较大, 为了使运算时间减少, 在统计滤波之前, 辅以半径滤波^[20]排除明显的离群点。对于点云 $\{\mathbf{P}\}$ 中的任意点 \mathbf{P}_i , 以其为中心构造半径为 r 的球域 $\{S_i \mid \|S_i - \mathbf{P}_i\| \leq r\}$ 。若 $\{S_i\}$ 的元素个数少于阈值 N , 则 \mathbf{P}_i 被半径滤波器视为噪声。例如, 设输入点云分布如图 12 所示, 分别以 $\mathbf{P}_1, \mathbf{P}_2$ 为球心, 半径为 r 构造球域, 当选择 $N = 4$ 时, 由于 \mathbf{P}_1 对应的球域中的点云数目小于 N , 则其将被视为噪声去除。




图 12 半径滤波示意图

Fig. 12 Schematic of radius filtering

半径滤波作为辅助方法, 不必强求取得最优阈值。在点云密度无法预知的情况下, 阈值 N 只需选择一个较小的保守值即可。相应地, 球域半径 r 选择一个较大的保守值。这样做能保证不会误删低密度点云。本文实例中, 取 $N = 40, r = 2$ 时能较好地去除明显的离群点同时保留边缘。以此为基础, 使用保守值 $N = 20$ 和 $r = 4$, 以确保主体结构点云边缘的完整性。由于同一视觉系统在同一固定场景下获得的点云密度差异不大, 所以这个阈值对本场景下的其他目标适用。

经过改进直通滤波、半径滤波、统计滤波后的三维点云如图 13(b) 所示。

3 实验与验证

为了验证算法的性能, 搭建实验平台进行多组对比实验。使用的主要设备如下: 两台维视 MV-EM200C 工业相机, 分辨率为 $1600 \text{ pixel} \times 1200 \text{ pixel}$; 圆标靶标定板; Intel Xeon E3-1250 v5 处理器; Nvidia GTX 750Ti 显卡; 12 GB 内存条; 相机固定架; 数显游标卡尺; 照明光源。图 14 为实验平台实物。

为方便描述, 约定算法 A 使用传统全局立体匹配获取三维点云; 算法 B 使用本文目标定位算法后直接获取三维点云, 不进行去噪; 算法 C 使用本文目标识别定位与点云去噪算法; 算法 D 使用传统全




图 13 去噪前后对比图。(a)原始点云;(b)去噪后点云

Fig. 13 Contrast before and after denoising. (a) Original point clouds; (b) denoised point clouds




图 14 实验平台

Fig. 14 Experimental platform

局立体匹配后,再使用本文点云去噪算法获得三维点云。

3.1 稳健性实验

稳健性实验主要考虑算法对各种复杂环境的敏感程度和适应性,能否正确可靠地定位出目标区域,为局部立体匹配提供关键位置信息。对于每一种复杂场景,向其中加入新目标,并获取其外包矩形框。图 15 为复杂场景下算法定位效果示意图,对于其中的各种场景都进行了多次实验,图中只给出其中一组,具体数据见表 1。相比于文献[1-5],本文算法具有更强的稳健性以及更高的识别率。




图 15 不同算法在复杂环境下的定位效果示意图。(a)~(d)背景杂乱、背景颜色与目标相近;
(e)目标堆叠、弱光;(f)背景杂乱、非线性光

Fig. 15 Schematic of location effect of different algorithms in complex environment. (a)-(d) Messy background with identical color; (e) stacked targets with weak light; (f) messy background with nonlinear light

表 1 新增目标识别率

Table 1 Recognizing rate of new targets

Scene	Number of targets	Number of recognized targets	Correct rate /%
Fig. 15(a)	46	46	100
Fig. 15(b)	52	50	96.2
Fig. 15(c)	21	20	95.2
Fig. 15(d)	50	50	100
Fig. 15(e)	50	46	92.0
Fig. 15(f)	50	44	88.0

3.2 运算效率实验

分 10 次将多个异形目标置于摄像机视场内,对采集所得的 10 对双目图像分别使用算法 A 和算法 C,分别记录两种算法中参与立体匹配的像素数以及运行时间,结果如图 16 所示。

在本实验条件下,传统算法运算量平均值为 532264 pixel,运算时间平均值为 18.773 s;本文算法运算量平均值为 54047 pixel,运算时间平均值为 3.746 s。本文算法在运算量及运算时间上远低于经典算法。

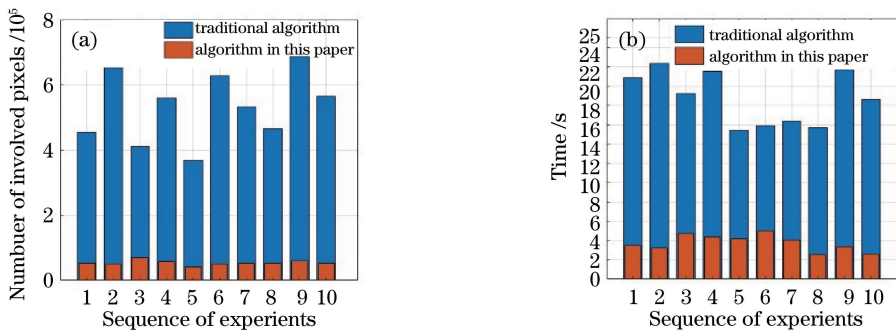


图 16 算法效率实验数据。(a)计算量对比;(b)运算时间对比

Fig. 16 Data of algorithm efficiency. (a) Contrast of calculation quantity; (b) contrast of running time

3.3 精度实验

分别对 5 个圆环、5 个方块、5 个齿轮,共 15 个工件逐一使用算法 A、算法 B、算法 C、算法 D 进行测量,并将其与数显游标卡尺的测量值进行比较。对于圆环工件,测量其外径;对于方块工件,测量其上底面 4 条棱长的均值;对于齿轮工件,测量其齿顶圆直径。4 种算法的测量误差如图 17 所示。

对比算法 A 与算法 B 的测量误差可知,本文算

法可以有效抑制噪声影响,提高后续生成三维点云的精度;对比算法 B 与算法 C 的测量误差可知,本文算法与识别定位算法结合可以进一步提高三维点云的精度;对比算法 A 与算法 D 可知,本文算法单独使用时也可以有效提高三维点云精度,但相比于与识别定位算法联合使用时效果大打折扣。综上所述,本文算法在测量精度上明显高于传统算法,同时算法的识别定位部分与点云去噪部分具有较好的相互扩展性。




图 17 算法误差实验数据。(a)圆环工件测量误差;(b)方块工件测量误差;(c)齿轮工件测量误差

Fig. 17 Experimental data of algorithm error.

(a) Cylinder measuring error; (b) square measuring error; (c) gear measuring error

4 结 论

1) 采用 RPCA 直接进行低秩数据与高秩数据分离,完成复杂环境下目标的分割,不依赖传统的分割特征,使分割算法与已有类似分割算法相比,在复杂环境下具有更强的适应能力,体现出较好的稳健性。

2) 采用形态学处理与 k -means 聚类互补的策略,前者为后者提供较为可靠的聚类初值和簇数,后者弥补了前者容易对图像产生破坏的缺点,在 RPCA 分割的基础上对各新增目标实现精确的图像定位,并通过 SVM 进一步筛选感兴趣区域,获得局部三维点云,使立体匹配计算量得以降低。

3) 基于坐标变换思想对直通滤波进行改进,把传统直通滤波三维阈值选择问题转化为一维问题,

有效降低点云的误删率,并联合改进的直通滤波、半径滤波、统计滤波降低目标特征的测量误差。

本文算法为复杂环境下多目标异形物体的定位与快速点云获取提供一种可供参考借鉴的算法与操作方法。

参 考 文 献

- [1] Liu N, Zou X J, Ye M, *et al.* Research of multiple workpieces positioning under complex environment [J]. Application of Electronic Technique, 2015, 41 (12): 120-123, 128.
刘念, 邹湘军, 叶敏, 等. 复杂环境下的多工件定位研究[J]. 电子技术应用, 2015, 41(12): 120-123, 128.
- [2] Li B, Chen Y, Zou X J, *et al.* Work-piece

- recognition of orientation chamfer matching based on twin-threshold segmentation [J]. Computer Engineering and Design, 2016, 37(3): 720-724.
- 李博, 陈燕, 邹湘军, 等. 基于二次阈值分割的方向倒脚匹配工件识别[J]. 计算机工程与设计, 2016, 37(3): 720-724.
- [3] Zou X J, Lin G C, Tang Y C, *et al.* Sub-pixel object-image registration using improved iterative closest point method[J]. Journal of Computer-Aided Design & Computer Graphics, 2016, 28(8): 1242-1249.
- 邹湘军, 林桂潮, 唐昀超, 等. 改进迭代最近点法的亚像素级零件图像配准[J]. 计算机辅助设计与图形学学报, 2016, 28(8): 1242-1249.
- [4] Wang X, Zhao Q C, Tan J P. Multiple circle location method using region estimation in complex background[J]. Journal of Central South University (Science and Technology), 2016, 47(7): 2266-2272.
- 王宪, 赵前程, 谭建平. 应用区域估计的复杂背景多圆快速定位方法[J]. 中南大学学报(自然科学版), 2016, 47(7): 2266-2272.
- [5] Li J, Yuan Y. Weak and small target detection under complicated background [J]. Computer and Digital Engineering, 2015, 43(3): 408-411.
- 李静, 袁媛. 复杂背景下弱小目标的检测[J]. 计算机与数字工程, 2015, 43(3): 408-411.
- [6] Wang Z Y, Hui Q. Design of processing technology of glass edging based on visual positioning [J]. Machine Tool & Hydraulics, 2017, 45(16): 29-31.
- 王再英, 惠强. 基于视觉定位的玻璃磨边加工工艺的设计[J]. 机床与液压, 2017, 45(16): 29-31.
- [7] Sun L, Abolhasannejad V, Gao L, *et al.* Non-contact optical sensing of asphalt mixture deformation using 3D stereo vision[J]. Measurement, 2016, 85: 100-117.
- [8] Mo S W, Deng X P, Wang S, *et al.* Moving object detection algorithm based on improved visual background extractor[J]. Acta Optica Sinica, 2016, 36(6): 0615001.
- 莫邵文, 邓新蒲, 王帅, 等. 基于改进视觉背景提取的运动目标检测算法[J]. 光学学报, 2016, 36(6): 0615001.
- [9] Huang X Y, Xu J L, Guo G, *et al.* Real-time pedestrian reidentification based on enhanced aggregated channel features [J]. Laser & Optoelectronics Progress, 2017, 54(9): 091001.
- 黄新宇, 许娇龙, 郭纲, 等. 基于增强聚合通道特征的实时行人重识别[J]. 激光与光电子学进展, 2017, 54(9): 091001.
- [10] Liu R, Wang D J, Jia P, *et al.* Point target detection based on omnidirectional morphological filtering and local characteristics criterion[J]. Acta Optica Sinica, 2017, 37(11): 1104001.
- 刘让, 王德江, 贾平, 等. 全方位形态学联合局部特征准则的点目标检测[J]. 光学学报, 2017, 37(11): 1104001.
- [11] Candès E J, Li X D, Ma Y, *et al.* Robust principal component analysis? [J]. Journal of the ACM, 2011, 58(3): 1-37.
- [12] Lin Z, Chen M, Ma Y. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[J]. arXiv, 2012: 1109.0367
- [13] Wu C W, Cao J P, Zhu Y H, *et al.* The global convergence analysis of augmented lagrange multiplier method for nonlinear optimization [J]. Journal of Pingxiang College, 2013, 30(3): 13-17.
- 吴聪伟, 曹继平, 朱亚红, 等. 基于约束优化问题乘子罚函数方法的全局收敛性分析[J]. 萍乡高等专科学校学报, 2013, 30(3): 13-17.
- [14] Hou Y F. The research of sparse representation based on low-rank and eigenface for face recognition [D]. Hefei: Anhui University, 2015: 20-58.
- 侯义福. 基于低秩与特征脸的稀疏表示人脸识别研究[D]. 合肥: 安徽大学, 2015: 20-58.
- [15] Rafael G, Richard W. Digital image processing[M]. Beijing: Publishing House of Electronics Industry, 2011: 66.
- [16] Heo Y S, Lee K M, Lee S U. Robust stereo matching using adaptive normalized cross-correlation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(4): 807-822.
- [17] Gray B, Adrian K. Learning OpenCV[M]. Beijing: Tsinghua University Press, 2012.
- [18] Zhang Q. Research of visual recognition algorithm for service robot based on PCL[D]. Hefei: University of Science and Technology of China, 2014.
- 张强. 基于点云库的服务机器人视觉识别算法研究[D]. 合肥: 中国科学技术大学, 2014.
- [19] Li R Z, Yang M, Ran Y, *et al.* Point cloud denoising and simplification algorithm based on method library [J]. Laser & Optoelectronics Progress, 2018, 55(1): 011008.
- 李仁忠, 杨曼, 冉媛, 等. 基于方法库的点云去噪与精简算法[J]. 激光与光电子学进展, 2018, 55(1): 011008.
- [20] Tian Q H, Bai R L, Li D. Point cloud segmentation

of scattered workpieces based on improved euclidean clustering [J]. Laser & Optoelectronics Progress, 2017, 54(12): 121503.

田青华, 白瑞林, 李杜. 基于改进欧氏聚类的散乱工件点云分割 [J]. 激光与光电子学进展, 2017, 54(12): 121503.