

DOI:10.19651/j.cnki.emt.2212113

基于改进 ORB-RANSAC 算法的锅底标签角度视觉测量方法^{*}

姚成贤¹ 张海峰¹ 范狄庆¹ 朱佳¹ 方宇¹ 沈志荣²

(1. 上海工程技术大学机械与汽车工程学院 上海 201620; 2. 上海裴椒汽车部件制造有限公司 上海 201612)

摘要: 传统 ORB-RANSAC 算法存在相似特征点误匹配率高、稳定性较差的问题,无法满足铝锅生产基于锅底标签方向焊接手柄的工艺要求,提出了一种改进的 ORB-RANSAC 算法。首先,采用 ORB 算法提取特征点并进行匹配,通过汉明距离阈值法对匹配点对进行粗剔除。其次,在 RANSAC 算法对匹配点对进行精剔除时,增加 K 折交叉验证实现对初始模型的一致性预判断。最后,在每次迭代过程中剔除上一轮迭代中的已归类点对,动态更新采样空间。分别对不同锅底标签进行测量实验,结果表明,在干扰环境下采用改进后的 ORB-RANSAC 算法重复性精度相比于原算法提升了 66.04%,单帧计算耗时降低了 6.13%;在多种类锅底标签测量实验中基于改进后的 ORB-RANSAC 算法的角度测量误差为 0.201°,平均检测耗时为 0.255 s,满足自动化生产测量精度和实时性的要求。

关键词: ORB-RANSAC 算法;机器视觉;图像处理;特征匹配

中图分类号: TP391.41 文献标识码: A 国家标准学科分类代码: 520.6040

Angle visual measurement method of pot bottom label based on improved ORB-RANSAC algorithm

Yao Chengxian¹ Zhang Haifeng¹ Fan Diqing¹ Zhu Jia¹ Fang Yu¹ Shen Zhirong²(1. School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China;
2. Shanghai Peijiao Autoparts Manufacturing Company, Shanghai 201612, China)

Abstract: The traditional ORB-RANSAC algorithm has the problems of high error matching rate and poor stability of similar feature points, which can not meet the technological requirements of welding handle based on the direction of bottom label in aluminum pot production. An improved ORB-RANSAC algorithm is proposed. Firstly, ORB algorithm was used to extract and match the feature points, and hamming distance threshold method was used to remove the matching points. Secondly, when RANSAC algorithm performs fine elimination of matching point pairs, k-fold cross-validation is added to achieve consistency pre-judgment of the initial model. Finally, the classified point pairs in the previous iteration are removed during each iteration, and the sampling space is dynamically updated. The results show that the repeatability accuracy of the improved ORB-RANSAC algorithm is improved by 66.04% compared with the original algorithm in the interference environment, and the single frame calculation time is reduced by 6.13%. The Angle measurement error based on the improved ORB-RANSAC algorithm is 0.201° and the average detection time is 0.255 s in the multi-type pot bottom label measurement experiment, which meets the requirements of automatic production measurement accuracy and real-time.

Keywords: ORB-RANSAC algorithm; machine vision; image processing; feature matching

0 引言

手柄焊接是铝锅生产线上一道重要的工序。大部分铝锅生产企业要求将手柄基于锅底标签方向进行定向焊接。

为了满足铝锅制造的工艺标准,焊接前的旋转修正误差要求不大于 0.5°,而目前这道工序多采用人工目视进行调整,效率低下、可靠性差,长时间重复性工作容易造成操作人员的高度疲劳,无法保证修正工序的误差要求。目前,虽然已

收稿日期:2022-11-17

*基金项目:国家自然科学基金(51905331)项目资助

经逐步采用了基于机器视觉的自动化焊接装置,在焊接前通过视觉测量算法测量标签偏转角度并自动进行旋转修正,实现了 500 ms 内的快速测量,但由于锅底标签种类繁多,且标签中含有大量重复特征,使旋转修正产生误差,导致出现焊歪的现象,影响良品率。因此,现阶段迫切需要一种自动化锅底标签角度测量方法,实现对于各类锅底标签的精准快速测量。

基于机器视觉的目标检测方法已经被广泛应用于实际生产领域。如采用通过特征提取对复杂背景下的条码进行高速识别^[1];通过边缘提取结合 PCA 算法对工件尺寸进行高速测量^[2];采用模板匹配的方法来获取酒瓶盖旋转角度和货车铰接角度^[3 4]。常用的图像匹配方法普遍采用 Harris 算子、尺度不变特征转换 (scale-invariant feature transform,SIFT) 算子、加速稳健特征 (speeded up robust features,SURF) 算子等,其中 SIFT 算子具有良好的鲁棒性,但计算耗时较长,无法满足自动化生产实时性的要求。为此,Rublee 等^[5]提出了定向 FAST 和旋转 BRIEF (oriented FAST and rotated BRIEF,ORB) 算法,由改进的加速分段测试特征点提取算法 (features from accelerated segment test,FAST) 算子和二进制鲁棒独立初等特征 (binary robust independent elementary features,BRIEF) 算子构成,理论速度是 SIFT 算法的 100 倍,但在精度上略逊于 SIFT 算法。在特征点粗匹配方面,目前普遍使用暴力匹配(brute force)算法和快速最近邻搜索包(fast library for approximate nearest neighbors,FLANN)匹配算法。为提升匹配精度,文献[6]采用基于多尺度多区域的特征提取方式提高了特征点的分布性,文献[7]对 ORB 的描述符进行改进,构造色相,饱和度,纯度(hue, saturation value, HSV)与 ORB 结合的特征描述向量。在对特征点精匹配方面,普遍采用随机抽样一致性算法(random sampling consensus,RANSAC)算法,但也存在着在运算量大和鲁棒性差的问题。文献[8]利用图像间相对变换关系结合对极几何约束的方法来去除误匹配特征点,文献[9]通过将剩余误匹配对剔除转化成极值优化的方法来提高匹配精度,文献[10]将 RANSAC 算法与整体最小二乘法相结合,提出了 RANSAC-WTLSR 算法来提高数据拟合精度,文献[11]通过反向匹配的方式对匹配点对进行二次匹配来提高算和 L-M(levengberg-marquardt) 算法来综合改进传统 RANSAC 算法,对匹配点对进行了提纯并计算出变换矩阵,文献[12]结合空间一致性检测理论、渐进式抽样策略(progressive sampling consensus,PROSAC) 算法和 L-M 算法来综合改进传统 RANSAC 算法,对匹配点对进行了提纯并计算出变换矩阵,提高了图像配准的准确性,但该算法面对重复特征的误匹配时无法进行有效的剔除。

本文针对传统 ORB-RANSAC 算法测量锅底标签旋转角度时稳定性较差的问题,提出了基于改进 ORB-RANSAC 算法的锅底标签角度测量方法。增加对初始模

型一致性的预判断以及迭代过程中采样空间的动态更新,在保证了算法实时检测的基础上,提高了图像匹配的精度。

1 现有 ORB-RANSAC 算法

1.1 ORB 算法原理

ORB 特征匹配算法是一种快速特征点提取及描述算法,整体分为两大部分,分别是基于 oriented FAST 的特征点提取以及基于 rotated BRIEF 的特征点描述。

1) 特征点提取

ORB 算法通过 FAST 算法来寻找特征点,FAST 的核心思想是找出那些局部像素灰度变化明显的点,即将一个点与周围一系列点比较像素值,如果与周围一定连续点像素值相差较大,则这个点被列为特征点。

2) 确定特征点方向

ORB 对特征点添加了旋转的描述,由灰度质心法(intensity centroid)实现。

(1)选取小区域 c, 定义图像块的距 m 为:

$$m_{pq} = \sum_{x,y \in c} x^p y^q I(x,y), p,q = \{0,1\} \quad (1)$$

(2)计算图像块的质心 C:

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (2)$$

(3)连接图像块的几何中心 O 与质心 C,得到一个方向向量 \overrightarrow{OC} ,作为该特征点的方向。

3) 特征描述

现有 ORB 算法采用 rotated BRIEF 描述子,通过一组二进制串来描述点的特征以及进行后续的匹配。假设(A,B)为特征点 P 在邻域 D 内基于特征点方向随机采样的一组点对,定义一计算方法 F:

$$F(P; A, B) = \begin{cases} 1, & I_A > I_B \\ 0, & I_A \leq I_B \end{cases} \quad (3)$$

式中: I_A 和 I_B 分别对应 A、B 两点的灰度值。

分别对每一组点对进行式(4)操作,并将结果按照预先采样顺序进行排列,得到该特征点 P 在其领域 D 内的一组 256 位二进制特征描述符 α_p ,即:

$$\alpha_p = \sum_{i=1}^{256} 2^{i-1} F(P; A_i, B_i) | (A_i, B_i) \in D \quad (4)$$

4) 特征点匹配

得到两幅图像中的所有特征点描述子后,分别计算两幅图像全体特征点描述子之间的汉明距离(Hamming distance)。汉明距离越小,两个特征点越相似,当汉明距离小于设定阈值时,即认为两个特征点匹配。

1.2 RANSAC 算法原理

RANSAC 算法是一种基于随机抽样的估计迭代算法,可以从一组包含“局外点”的观测数据集中通过迭代方式估计数学模型的参数^[13]。应用于本案例下的算法主要步骤如下:

1) 随机采样 4 组点对形成初始模型

2) 利用初始模型对其余点对进行验证,得到符合要求

的内点个数。

3) 重复步骤 1)~2) 进行迭代, 找出符合的内点数最多的模型作为最优模型并输出。

1.3 现有算法问题

现有 ORB 算法在汉明距离阈值法粗剔除的基础上采用 RANSAC 算法进行误匹配点对的精剔除, RANSAC 算法首先需要在总体样本中随机采样点对形成初始模型 s_{start} , 模型中所有点对应满足:

$$\begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \mathbf{H} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & 1 \end{pmatrix} \cdot \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (5)$$

式中: (x, y) 和 (x', y') 为一组匹配点对, 单应性矩阵 H 体现了两幅图像的平移、旋转和缩放变换。要想确定矩阵 H 中 8 个参数, 则一共需要 4 组点对。当粗剔除的阈值设置的不合理时会保留较多的误匹配点对^[14], 这些点对若被引入矩阵 H 的计算中, 会导致 RANSAC 迭代次数的上升, 从而影响算法效率。

图 1 为一种较特殊的锅底标签, 存在较多相似特征并且整体呈几何对称, 这会导致在特征点匹配阶段产生相当一批满足局部一致性的匹配点对, 如图 1 中 $\{S_2, S_3\}$ 点对为误匹配点对, 其余点对虽为正确匹配点对, 但其中只有 $\{S_1, S_5, S_6\}$ 和 $\{S_4, S_7\}$ 这两组点对内部满足一致性而组与组之间不满足, 这一现象会使 RANSAC 迭代次数的上升的问题更加严重。传统 RANSAC 算法基于最大迭代次数和最小错误率来判定是否跳出主循环。基于计算最小错误率能够在得出较好模型时跳出循环, 以节约算法计算时间, 但精度和效率受阈值设置影响较大, 不合理的阈值容易使算法陷入死循环。为此算法在原有基础上增加了

最大迭代次数限制, 能够保证在一定计算时间内输出最佳模型参数, 但在特定环境下重复性计算较多, 计算效率受到一定影响。

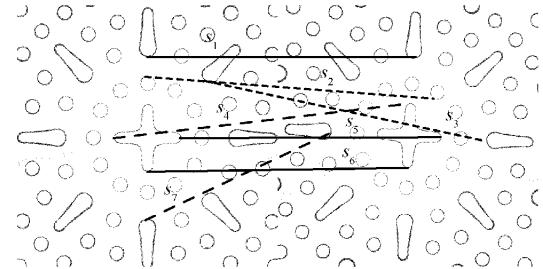


图 1 特殊锅底标签样式

2 改进 ORB-RANSAC 算法

针对传统 RANSAC 算法在本文研究中遇到的问题, 对 RANSAC 算法进行改进, 通过引入对初始模型 s_{start} 的预判断和采样空间的优化, 在保证初始模型满足一致性的条件下, 动态更新采样空间, 减少算法的重复性计算, 提升计算效率。

2.1 初始模型的一致性预判断

对 RANSAC 算法增加 K 折交叉验证(K-fold cross validation)实现对初始模型 s_{start} 的一致性预判断(下文简称 KF-RANSAC 算法), 即验证初始模型中是否含有误匹配点对, 具体流程如图 2 所示。首先将初始采样点对数从 4 个扩充成 5 个, 将模型中每组点对分别作为验证点, 其余 4 组点对用于计算单应性矩阵 H , 若 5 次验证中验证点对均适用于矩阵 H , 则初始模型验证通过, 进行下一步模型扩充, 否则重新对初始模型进行采样。

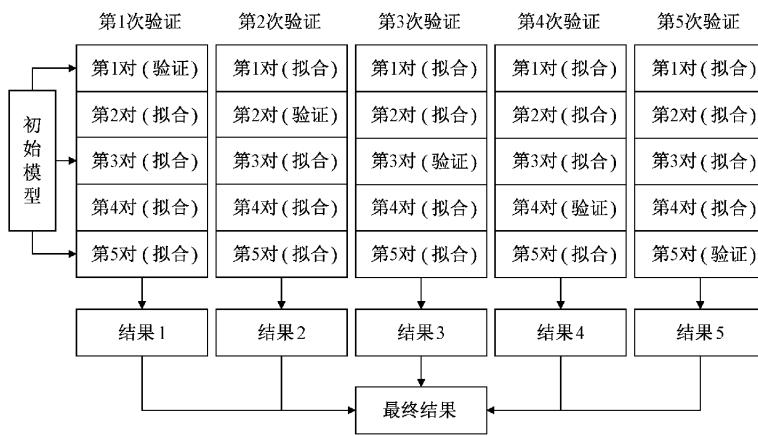


图 2 一致性预判断流程

现假设样本总数 N_s , 误匹配率 w , 从总体样本中随机采样 5 组点对形成初始模型 s_{start} , 则该模型满足一致性(即模型中不存在误匹配点)的概率 $p_{correct}$ 为:

$$p_{correct} = \prod_{i=1}^5 \frac{N_s(1-w) - i}{N_s - i} \approx (1-w)^5 \quad (6)$$

假设迭代次数 n_{iter} , 采样时间 t_{sample} , 拟合模型时间 t_{match} , 判别时间 t_{judge} 。基于最大迭代次数的 RANSAC(简称 RANSAC-iter)算法理论耗时 T_{RANSAC_iter} 可由下式得出:

$$T_{RANSAC_iter} = n_{iter} [4 \cdot t_{sample} + 2 \cdot t_{match} + (N_s - 4) \cdot t_{judge}] \quad (7)$$

基于最小错误率的 RANSAC(简称 RANSAC-err)算法理论耗时 $T_{RANSAC-err}$ 可由下式得出:

$$T_{RANSAC-err} = \frac{1}{P_{correct}} [4 \cdot t_{sample} + 2 \cdot t_{match} + (N_S - 4) \cdot t_{judge}] \quad (8)$$

则传统 RANSAC 算法的理论耗时满足:

$$T_{RANSAC} \in [T_{RANSAC-err}, T_{RANSAC-iter}] \quad (9)$$

当误匹配率 w 较低时:

$$T_{RANSAC} \rightarrow T_{RANSAC-err} \quad (10)$$

当有一定误匹配率时:

$$T_{RANSAC} \rightarrow T_{RANSAC-iter} \quad (11)$$

加入了对初始模型判断的改进 RANSAC 算法理论用时 $T_{KF-RANSAC}$ 由下式得出:

$$\begin{aligned} T_{KF-RANSAC} &= n_{iter}(1 - P_{correct}) \\ &[5 \cdot t_{sample} + 5(t_{match} + t_{judge})] + n_{iter}P_{correct} \\ &[5 \cdot t_{sample} + 5(t_{match} + t_{judge}) + (N_S - 5) \cdot t_{judge} + t_{match}] \end{aligned} \quad (12)$$

令 $T_{judge} = 5(t_{match} + t_{judge})$, T_{judge} 为一次对初始模型预判断的时间, 则式(13)可化简为:

$$\begin{aligned} T_{KF-RANSAC} &= n_{iter}T_{judge} + n_{iter}P_{correct} \\ &[5 \cdot t_{sample} + (N_S - 5) \cdot t_{judge} + t_{match}] \end{aligned} \quad (13)$$

当误匹配率 w 较低时, $P_{correct} \rightarrow 1$, 此时式(13)可近似写成:

$$\begin{aligned} T_{KF-RANSAC} &\approx n_{iter}T_{judge} + n_{iter} \\ &[5 \cdot t_{sample} + (N_S - 5) \cdot t_{judge} + t_{match}] > T_{RANSAC} \end{aligned} \quad (14)$$

当有一定误匹配率时, 结合式(7)、(11)和(13)得:

$$\begin{aligned} T_{RANSAC} - T_{KF-RANSAC} &\approx n_{iter}(N_S - 5) \cdot t_{judge}(1 - P_{correct}) - \\ &n_{iter}T_{judge} \approx 0 \end{aligned} \quad (15)$$

从式(14)可以得出: 当误匹配率 w 较低时传统 RANSAC 算法效率上具有一定优势。从式(15)可以得出: 当存在一定误匹配率时, KF-DYNSAC 算法用时接近传统 RANSAC 算法。

2.2 采样空间动态更新

对 KF-RANSAC 算法的计算流程进行分析, 不难发现在 n_{iter} 次迭代过程中, 有相当大一部分的迭代流程都是在重复验证一系列高度相似模型, 增加了算法的重复计算量。针对此问题, 本算法对采样空间进行改进, 在 2.1 节 KF-RANSAC 的基础上提出了 KF-DYNSAC 算法, 从第 2 轮迭代开始, 采样空间从原先的总体样本改为从总体样本中剔除上一轮迭代的终止模型(对初始模型进行模型扩充后的集合), 即:

$$S^i = S^{i-1} - s_{end}^{i-1} \quad (16)$$

$$N_S^i = N_S^{i-1} - N_{s,end}^{i-1} \quad (17)$$

式中: S^i 为第 i 次迭代的采样空间, s_{end}^{i-1} 为第 $i-1$ 次迭代的终止模型, N_S^i 为第 i 次迭代的采样空间大小, $N_{s,end}^{i-1}$ 为第 i 次迭代终止模型的大小。

则 KF-DYNSAC 算法理论耗时 $T_{KF-DYNSAC}$ 由下式

得出:

$$T_{KF-DYNSAC} = \sum_{i=1}^n \left[\frac{T_{judge}}{P_{correct}^i} + (N_S^i - 5) \cdot t_{judge} + t_{match} \right] \quad (18)$$

当误匹配率 w 较低时, $P_{correct} \rightarrow 1, N_{s,end} \rightarrow N_S$

式(18)可近似写成:

$$T_{KF-DYNSAC} \approx T_{judge} + (N_S - 5) \cdot t_{judge} + t_{match} \quad (19)$$

用时接近 KF-RANSAC 算法完整迭代一次左右的用时。

当存在一定误匹配率时, 由于每次迭代时的采样空间相比上一轮迭代有所减少, 故在算法速度上也有一定的提升。

KF-DYNSAC 算法流程如图 3 所示, 具体步骤如下:

- 1) 随机采样 5 组点对形成初始模型
- 2) 对初始模型进行一致性预判断, 若通过则进行下一步操作, 否则对初始模型进行重新采样。
- 3) 将步骤 1)~2) 中所得初始模型对样本空间内其余点对进行单应性变换验证, 计算点对变换后的欧式距离, 若该距离小于设定阈值, 则被验证点对为内点, 并扩充至此模型。
- 4) 统计当前模型内点个数, 若多于最优模型内点个数, 则更新当前模型为最优模型, 否则进行下一步操作。
- 5) 计算已被归类的点对占总体样本数比例, 若大于设定阈值则算法结束, 否则对采样空间进行更新并进行下一步迭代。

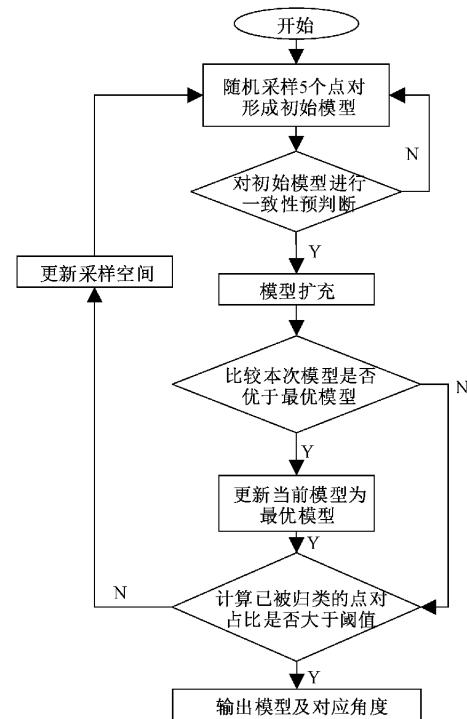


图 3 KF-DYNSAC 算法流程

3 实验与分析

考虑到 Jetson Nano 具有图像处理能力强、功耗低、性价比高的特点,本文将其作为硬件平台^[15],操作系统为 Ubuntu18.04。实验相机为海康威视 MV-CE050-31GM 搭配 8 mm 镜头,光源为 90°光源。测试的铝锅样本均来自于铝锅生产企业实际流水线,为保证测试样本的多样性,同一型号铝锅将从不同批次内进行选取。分别对锅底进行 50 帧连续采集检测,记录每一帧测量角度以及检测耗时以比较在理想环境、干扰环境和特殊环境下算法的精度以及稳定性,采用重复性精度(相对误差)、单帧平均耗时和稳定性(检测耗时的标准差)来作为衡量算法性能的指标^[16]。进一步,对 12 种锅底标签共计 600 个样本进行单帧检测,结合人工手动测量结果进行对比,采用绝对误差和每帧检测时间来作为衡量算法性能的指标。

3.1 理想环境下算法对比实验

随机选取一口铝锅用于模板制作,将铝锅旋转一定角度,并用此模板对其进行特征匹配及测量。验证算法在理想环境下(误匹配率低)的精度及耗时。测试铝锅标签图像如图 4 所示,测试精度及耗时变化曲线如图 5 所示。

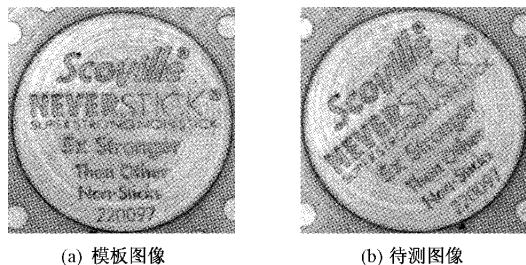


图 4 锅底标签图像

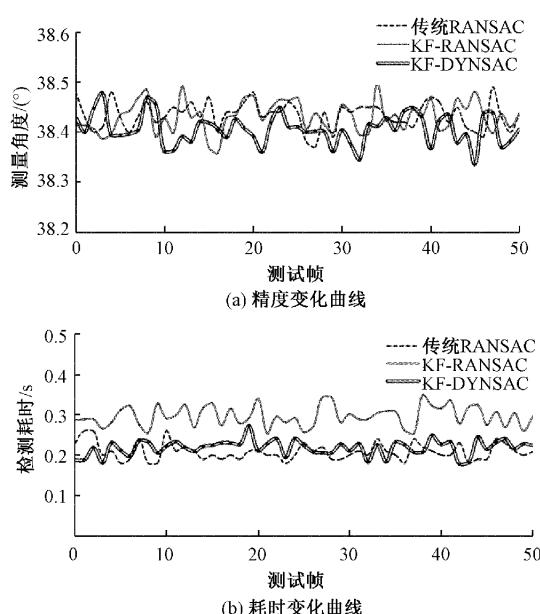


图 5 理想情况下算法精度耗时变化曲线

从图 5 中可以看出,3 种算法在理想环境下都有着良好的精度和稳定性,在算法效率方面,传统 RANSAC 算法基于最小错误率来实现跳出主循环,故在速度方面有一定的优势,而 KF-RANSAC 和 KF-DYNSAC 算法相比原算法增加了预判断的流程,在理想情况下耗时会有一定的增加。3 种算法在理想情况下的性能指标如表 1 所示。

表 1 理想情况下算法检测性能对比

| 算法 | 重复性精度/ ° | 单帧平均耗时/ s | 稳定性 |
|-----------|-------------|--------------|-------|
| 传统 RANSAC | 0.09 | 0.208 | 0.021 |
| KF-RANSAC | 0.14 | 0.297 | 0.026 |
| KF-DYNSAC | 0.12 | 0.225 | 0.020 |

表 1 的实验数据显示在理想状况下,传统 RANSAC 凭借着更简洁的算法流程,在计算效率方面优于 KF-RANSAC 算法 42.79%,优于 KF-DYNSAC 算法 8.17%。

3.2 干扰环境下算法对比实验

随机选取一口铝锅,将标签处涂上油墨进行部分遮挡以模拟实际生产过程中锅底上残留一定的油污,模板与实验 1 中模板一致,验证在实际生产环境中(存在一定误匹配率)3 种算法的测量精度和耗时。测试铝锅标签图像如图 6 所示,测试精度及耗时变化曲线如图 7 所示。

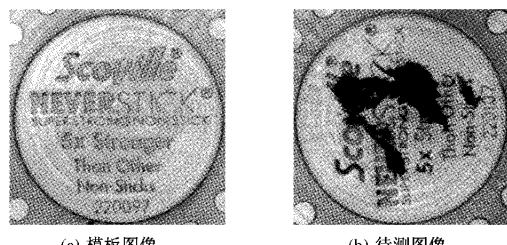


图 6 锅底标签图像

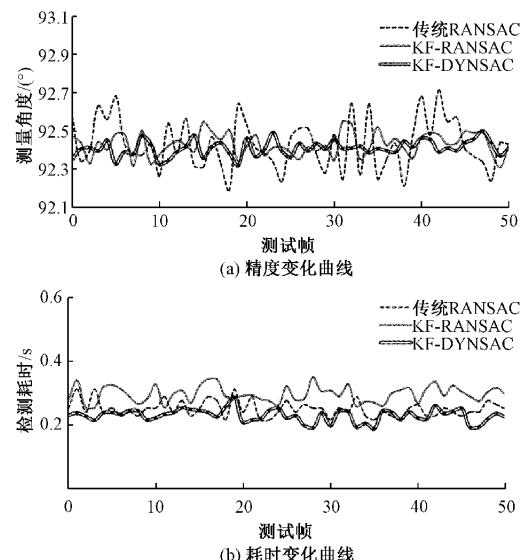


图 7 干扰情况下算法精度耗时变化曲线

从图 7(a)可以看出,由于人为引入一定干扰信息,传统 RANSAC 算法的精度明显低于 KF-RANSAC 和 KF-DYNSAC 算法,而 KF-RANSAC 和 KF-DYNSAC 算法由于引入了对初始模型的预判断流程,在精度方面依然有着良好的表现。3 种算法在干扰情况下的性能指标如表 2 所示。

表 2 干扰情况下算法性能对比

| 算法 | 重复性精度/ (°) | 单帧平均耗时/ s | 稳定性 |
|-----------|---------------|--------------|-------|
| 传统 RANSAC | 0.53 | 0.250 | 0.137 |
| KF-RANSAC | 0.24 | 0.315 | 0.062 |
| KF-DYNSAC | 0.18 | 0.235 | 0.042 |

表 2 显示在干扰情况下 3 种算法在精度和效率方面相比于理想情况都有不同程度的降低,其中传统 RANSAC 算法在精度上和速度上降幅最大,分别为 488.89% 和 20.19%,而 KF-RANSAC 由于增加了预判断的流程,在误匹配率较高时保证了初始模型的一致性,精度和效率方面下降幅度分别为 71.43% 和 6.06%,KF-DYNSAC 算法在 KF-RANSAC 算法的基础上对采样空间做出优化,精度和效率方面下降幅度分别为 50% 和 4.44%。数据结果表明 KF-DYNSAC 算法在受到外界干扰的情况下具有更好的鲁棒性。

3.3 特殊环境下算法对比实验

采用 1.3 节中图 1 所示锅底标签为实验对象,随机取两口此类型锅,其中一口作为模板,一口作为待测样本,验证 3 种算法面对样本中存在高度相似特征时的匹配测量效果。测试铝锅标签图像如图 8 所示,测试精度及耗时变化曲线如图 9 所示。

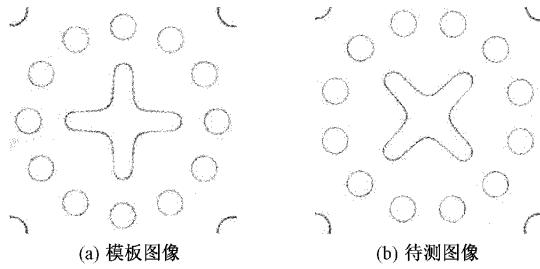


图 8 锅底标签图像

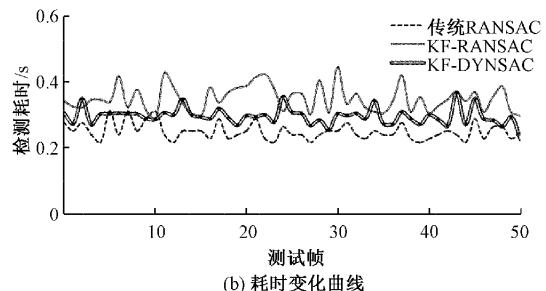
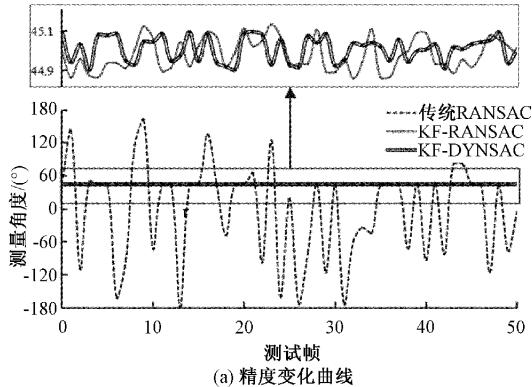


图 9 特殊情况下算法精度耗时变化曲线

从图 9(a)可以看出,传统 RANSAC 算法对图像具有高度重复特征时无法进行有效的匹配,测量结果发生震荡;KF-RANSAC 算法和 KF-DYNSAC 算法在此情况下能够进行有效的匹配,但较高的误匹配率和大量的重复计算导致 KF-RANSAC 算法效率受到了较大的影响。3 种算法在特殊情况下的性能指标如表 3 所示。

表 3 特殊情况下算法性能对比

| 算法 | 重复性精度/ (°) | 单帧平均耗时/ s | 稳定性 |
|-----------|---------------|--------------|-------|
| 传统 RANSAC | — | — | — |
| KF-RANSAC | 0.29 | 0.60 | 0.040 |
| KF-DYNSAC | 0.19 | 0.338 | 0.025 |

注:传统 RANSAC 实验结果为无效数据,故不做记录

表 3 的实验数据显示 KF-RANSAC 和 KF-DYNSAC 算法在应对此类特殊情况时依然有着良好的重复性精度,KF-DYNSAC 引入的动态采样空间方法在此类情况下对算法速度的提升幅度最明显,达到了 43.67%,精度方面相比于 KF-RANSAC 也提升了 34.48%。

3.4 KF-DYNSAC 算法面对多种类标签测量实验

分别对 12 种样式锅底进行单帧图像检测以模拟实际生产流程,锅底标签样式如图 10 所示,其中样式 1~4 验证算法面对图像中含有高度重复性特征时的性能,样式 5~8 验证算法面对干扰环境下误匹配率高时的性能,样式 9~12 考验算法在良好环境下的性能表现。每种锅底含 50 个样本,共计 600 个样本。对采集的每一样本图像分别进行算法测量以及人工手动测量,记录每一样本的误差以及检测时间,实验部分数据如表 4 所示。



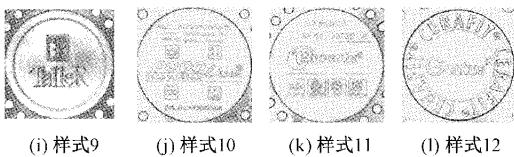


图 10 锅底标签样式一览图

表 4 KF-DYNSAC 算法针对多种类样本的实际性能

| 样式 | 特点 | 平均误差/(°) | 平均检测时间/s |
|----|-------|----------|----------|
| a | | 0.246 | 0.345 |
| b | 相似特征多 | 0.174 | 0.280 |
| c | 误匹配率高 | 0.225 | 0.262 |
| d | | 0.235 | 0.211 |
| e | | 0.150 | 0.247 |
| f | 表面粗糙 | 0.229 | 0.250 |
| g | 干扰噪声多 | 0.264 | 0.241 |
| h | | 0.281 | 0.274 |
| i | | 0.189 | 0.237 |
| j | 相似特征少 | 0.147 | 0.242 |
| k | 背景干扰少 | 0.143 | 0.245 |
| l | | 0.132 | 0.224 |

表 4 显示 KF-DYNSAC 算法在面向实际生产环境下多类型锅底的检测时有着良好的性能,面对相似特征多的锅底标签测量平均误差为 0.220° ,平均测量耗时为 0.275 s ;面对表面粗糙的锅底标签测量平均误差为 0.231° ,平均测量耗时为 0.253 s ;面对相似特征少、背景干扰少的锅底标签测量平均误差为 0.153° ,平均测量耗时为 0.237 s ,满足自动化测量精度和实时性的要求。

4 结 论

为满足铝锅锅底标签角度测量实时性和稳定性的需求,针对传统 ORB-RANSAC 算法鲁棒性较差的问题,提出了 KF-DYNSAC 算法,引入对初始模型的一致性预判断并对采样空间动态更新,实验结果表明:

KF-DYNSAC 算法在干扰情况下的测量重复性精度为 0.24° ,单帧平均耗时仅为 0.235 s 。重复性精度在理想和干扰环境下的差距较传统 RANSAC 算法下降了 417.46% ,较 KF-RANSAC 算法下降了 21.43% ;单帧平均耗时在在理想和干扰环境下的差距较传统 RANSAC 算法下降了 14.13% ,较 KF-RANSAC 算法下降了 1.62% ,具有更好的鲁棒性。

KF-DYNSAC 算法实现了特殊环境下对含高度重复性特征的图像检测,同时相较于 KF-RANSAC 算法在重复性精度方面提升了 34.48% ,单帧平均耗时降低了 43.67% 。

KF-DYNSAC 算法能够有效对多种类型锅底标签角度进行测量,因锅底标签样式特点不同,平均误差在

$0.132^\circ \sim 0.281^\circ$ 之间浮动,平均检测时间在 $0.211 \sim 0.345\text{ s}$ 之间浮动,实现了自动化测量快速精准的要求。

现有算法所处理的特征尺度单一,导致无法有效处理图像中存在多尺度特征的情况,下一步将对多尺度特征融合的 ORB 算法进行研究。

参 考 文 献

- [1] 李少波,王铮,杨静,等. 基于机器视觉的一维和二维条码高速在线识别[J]. 计算机集成制造系统, 2020, 26(4): 947-953.
- [2] 赵朝朝,江明,殷宗琨. 改进 Canny 算子下的工件尺寸测量[J]. 电子测量与仪器学报, 2022, 36(8): 52-59.
- [3] 刘浩南,张辉,吴成中,等. 基于机器视觉的口杯酒瓶盖旋转角度测量方法[J]. 测控技术, 2019, 38(10): 24-29.
- [4] SAXE C D, CEBON D. A visual template-matching method for articulation angle measurement[C]. 2015 IEEE 18th International Conference on Intelligent Transportation Systems, 626-631.
- [5] RUBLEE E, RABAUD V, KONOLIGE K, et al. ORB: An efficient alternative to SIFT or SURF[C]. International Conference on Computer Vision, 2011: 2564-2571.
- [6] 齐乃新,杨小冈,李小峰,等. 基于 ORB 特征和 LK 光流的视觉里程计算法[J]. 仪器仪表学报, 2018, 39(12): 216-227.
- [7] ZHUO L, GENG Z, ZHANG J, et al. ORB feature based web porno graphic image recognition [J]. Neurocomputing, 2016, 173(3): 511-517.
- [8] 任彬,宋海丽,赵增旭,等. 基于 RANSAC 的视觉里程计优化方法研究[J]. 仪器仪表学报, 2022, 43(6): 205-212.
- [9] 邢凯盛,凌有铸,陈孟元. ORB 特征匹配的误匹配点剔除算法研究[J]. 电子测量与仪器学报, 2016, 30(8): 1255-1262.
- [10] 张中岳,周惠兴,王舜,等. 基于 RANSAC 的 WTLS 平面拟合算法研究[J]. 国外电子测量技术, 2022, 41(6): 93-98.
- [11] 程漫颖,姚敏茹,曹凯,等. 基于二次匹配策略的 RANSAC 算法研究[J]. 电光与控制, 2021, 28(6): 38-41, 51.
- [12] 雷思文,朱福珍. 基于 ORB 和改进 RANSAC 的无人机遥感图像配准算法[J]. 黑龙江大学自然科学学报, 2020, 37(5): 623-630.
- [13] 张潇丹,单彦虎,储成群. 基于点云处理的小型工业零件高度精密测量[J]. 电子测量技术, 2022, 45(11): 134-139.
- [14] 张盟,王志亮,刘汉忠. 基于 ORB 特征的图像误匹配剔除算法研究[J]. 南京工程学院学报(自然科学版),

2021, 19(1): 24-28.

- [15] 罗平, 虞俊锋, 邱富康. 基于 Jetson Nano 的智能门禁系统[J]. 实验室研究与探索, 2022, 41(5): 130-134.
- [16] 廖泓真, 王亮, 孙宏伟, 等. 一种改进的 ORB 特征匹配算法[J]. 北京航空航天大学学报, 2021, 47(10): 2149-2154.

作者简介

姚成贤,硕士研究生,主要研究方向为机器视觉与图像处理。

E-mail:1017317072@qq.com

张海峰(通信作者),博士,副教授,主要研究方向为机器视觉技术与应用、交通能源系统优化运行与控制。

E-mail:15901866629@163.com

范狄庆,硕士,讲师,主要研究方向为机器视觉,自动化制造技术应用与开发。

E-mail:fdq1112@163.com

朱佳,硕士研究生,主要研究方向为机器视觉与深度学习。

E-mail:877708401@qq.com

方宇,博士,教授,主要研究方向为面向电力系统的特征机器人及智能装备研发、机器视觉与图像检测技术。

E-mail:fangyu_hit@126.com

沈志荣,主要从事制造业自动化技术应用管理与实践。

E-mail:zr.shen@sh-pjqp.com