

DOI:10.3969/j.issn.1001-4551.2019.03.002

基于 PX-LBP 和像素分类的装配体零件识别研究*

田中可, 陈成军*, 李东年, 赵正旭
(青岛理工大学机械与汽车工程学院, 山东 青岛 266033)

摘要:针对机械产品装配维修诱导中零件和装配体的识别、监测问题,对装配体零件识别及装配监测进行了研究,对 LBP 算子进行了改进,提出了一种基于像素局部二值模式(PX-LBP)和像素分类的装配体零件识别及装配监测方法。首先将 LBP 算子与像素分类融合,提出了 PX-LBP 算子;然后对深度图像进行了 PX-LBP 特征提取,生成了训练集和测试集;最后训练随机森林分类器,并利用训练好的随机森林分类器实现了对测试集深度图像的像素分类,生成了像素预测图像,通过像素预测图像与标记图像对比实现了装配体零件的识别及装配过程的监测。研究表明:该方法对于模型深度图像的像素识别率可达到 98.81%,对于真实装配体深度图像的像素识别率也可达到 77.51%;该方法兼具了一定的实时性与鲁棒性,可用在装配维修诱导、装配监测和自动化装配邻域中。

关键词:零件识别;装配监测;深度图像;像素局部二值模式;像素分类;随机森林分类器

中图分类号:TH161+.7;TP391.41

文献标志码:A

文章编号:1001-4551(2019)03-0236-08

Recognition of assembly parts based on PX-LBP and pixel classification

TIAN Zhong-ke, CHEN Cheng-jun, LI Dong-nian, ZHAO Zheng-xu

(School of Mechanical & Automotive Engineering, Qingdao University of Technology, Qingdao 266033, China)

Abstract: Aiming at issue of parts recognition and assembly monitoring in assembly maintenance and guidance of mechanical products, a part recognition and assembly monitoring method based on Pixel Local Binary Pattern (PX-LBP) was proposed. Firstly, the classical LBP operator was merged with the pixel classification to propose an improved LBP operator, which is named PX-LBP operator. Secondly, PX-LBP features of the depth images were extracted. And training set and test set were obtained. Finally, the randomized decision forests classifier was trained. Then the pixel classification of the depth image of the test set was executed to get the pixel prediction image of depth images. The recognition of assembly parts was realized by comparing the RGB values of pixel prediction image and the corresponding color label image. The assembly process monitoring was realized by analyzing the number and position of pixels in pixel prediction image of each assembly part to determine the assembly error. Experiment results show that the method proposed in this paper has high accuracy, real-time and robust ability, and can be used in fields of assembly maintenance guiding, assembly monitoring and automatic assembly.

Key words: part recognition; assembly monitoring; depth image; pixel local binary pattern; pixel classification; randomized decision forests classifier

0 引言

大型复杂机械装备涉及的装配知识较多,装配过程中工人难免会出现装配错误,因此,需要一种智能化

的装配监测系统,智能识别装配体各零件并监测装配过程。

目前,监测已广泛应用于生产中,特别是产品装配领域,如 CAO 等^[1]提出了基于射频识别的车间实时数据驱动监测技术;YIN 等^[2]提出了一种面向飞机装配

收稿日期:2018-10-09

基金项目:国家自然科学基金资助项目(51475251, 51705273);山东省重点研发计划资助项目(2017GGX203003)

作者简介:田中可(1989-),男,山东菏泽人,硕士研究生,主要从事零件识别及装配监测方面的研究。E-mail:1321990585@qq.com

通信联系人:陈成军,男,教授,硕士生导师。E-mail:chenchengjun79@163.com

过程监测的RFID布局方法,满足了飞机装配过程的监测要求;周铨^[3]针对过盈装配过程中的质量控制和数据采集问题,提出了过盈压装装配工序的过程监测系统;陈培等^[4]设计了基于ARM的线缆智能生产监控系统,满足了线缆生产自动化控制中的监测要求;汪嘉杰等^[5]提出的基于视觉的航天电连接器智能识别与装配引导方法,实现了航天电连接器的装配监测。以上成果针对具体产品的装配需求,实现了装配过程中的监测功能,但对机械产品装配维修诱导中零件和装配体的识别、监测问题相关研究较少。

OJALA等^[6]在1996年提出LBP算子,是一种有效的纹理特征提取算法,后经过了扩展LBP算子和旋转不变性LBP算子^[7]、MB-LBP^[8]、CS-LBP^[9]、DLBP^[10]、LQP^[11]、CELBP^{NT}^[12]以及CS-LSBP^[13]等多次改进。虽然改进后的LBP算子已有了很大提高,但以上改进大多针对纹理分析和人脸识别领域,使用的图像多为灰度图像,识别单元多为整幅图像,即每幅图像产生1组特征值向量。

针对装配体零件识别与监测问题,受SHOTTON等人^[14]将深度差分特征与像素分类相融合及田野等人^[15]将LBP与多层DCT相融合启发,本文将提出把PX-LBP与像素分类相融合的方法。

1 算法框架

基于PX-LBP和像素分类的零件识别及装配监测算法的整体框架如图1所示。




图1 算法框架

具体步骤为:首先获取深度图像包括模型的合成深度图像和装配体的真实深度图像,并利用PX-LBP算子对深度图像进行特征提取,使用模型的合成深度图像建立训练集和合成测试集,使用装配体的真实深度图像建立真实测试集;然后建立随机森林分类器,通过带有颜色标签的训练集训练随机森林分类器,确定各相关参数;最后,用随机森林分类器对装配体深度图像进行像素分类,获取像素预测图像,通过分析、对比像素预测图像识别装配体中的各零件并监测装配过程。

2 样本集的建立

建立样本集主要包括合成模型深度图像和采集真实装配体深度图像。在合成模型深度图像时,本文首先建立三维装配体模型,用不同的颜色对模型中的不同零件进行标记^[16];然后,利用OSG三维渲染功能以图形渲染方式生成所需模型的深度图像及对应的标签图像;最后,选择不同视角下的深度图像及标签图像建立样本集。在采集真实装配体深度图像时,利用Kinect 2.0采集真实装配体的深度图像,并对所采集的深度图像进行预处理,主要包括空洞填充和平滑处理。

空洞是指原始深度图像中深度值无效的区域。空洞填充是指修复原始深度图像的空洞区域。由于黑洞的灰度值为0,而白洞的灰度值为205,受刘继忠等^[17]对深度图像修复处理的启发,本文进行空洞填充,即:

$$S(x,y) = \begin{cases} M_{\Omega}, (D(x,y) = 205 \cap N_{\Omega}(x,y) > 0) \\ \cup D(x,y) = 0 \\ D(x,y), \text{其他} \end{cases} \quad (1)$$

式中: $S(x,y)$ —经过空洞填充处理后的灰度值; Ω —像素点 (x,y) 的一个方形邻域; M_{Ω} —邻域 Ω 中非0深度值的众数(频率最高的深度值); $D(x,y)$ —原始灰度值; $N_{\Omega}(x,y)$ —邻域 Ω 中非205像素点数。

最后,本研究用中值滤波对空洞填充后的深度图像进行平滑处理,用以去除噪音。

3 PX-LBP特征提取算子

3.1 经典LBP算子

LBP算子定义:以中心像素点的灰度值为阈值,将其周围8个像素点的灰度值分别与中心像素点的灰度值进行比较,若小于中心像素点的灰度值,则该像素位置被标记为0,否则标记为1;然后,将阈值化后的二进制数值转化为十进制数,即对应位置分别乘以 $1, 2, 4, \dots, 2^{n-1} (n \in \mathbf{N})$,然后求和作为该中心像素点的LBP特征值,具体计算如下:

$$\text{LBP}_N = \sum_{i=0}^{N-1} s(p_i - p_c) 2^i, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

式中: p_c —该领域中心像素的灰度值; N —采样点数; $p_i (i = 0, \dots, N-1)$ — N 个采样像素点的灰度值。

后来,OJALA等又将上述LBP的方形邻域换成圆形邻域,提出了扩展的LBP算子,同时提出了旋转不变的LBP算子,分别如下:

$$\text{LBP}_{N,R} = \sum_{i=0}^{N-1} s(p_i - p_c) 2^i, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

式中: R —圆形邻域的半径; p_c —邻域中心像素的灰度值; $p_i (i = 0, \dots, N-1)$ — N 个采样像素点的灰度值; N —采样点数。

$$\text{LBP}_{N,R} = \min(\text{ROR}(\text{LBP}_{N,R}, i)), i = 0, 1, \dots, N-1 \quad (4)$$

式中: $\text{ROR}(x, i)$ —旋转函数,表示将 x 循环右移 $i (i < p)$ 位。

MB-LBP 算子把邻域像素点扩展到邻域像素矩形区域,以矩形区域所有像素点灰度值的平均值作为阈值,用像素块之间的平均灰度值比较代替传统 LBP 算子像素点之间灰度值的比较。

近期,胡敏等将 LBP 与 CS-LBP 相结合,提出了 CS-LSBP,一定程度上既考虑了各邻域像素点灰度值之间的关系,又考虑了中心像素点与其邻域像素点灰度值之间的对比关系,即:

$$\text{CS-LSBP}_{N,R} = \sum_{i=0}^{(N/2)-1} X(p_i, p_c, p_{i+(N/2)}) 2^i \quad (5)$$

$$X(x, y, z) = \begin{cases} 1, & y \in [x, z] \\ 0, & \text{其他} \end{cases} \quad (6)$$

式中: x —采样像素点 p_i 所对应的灰度值; y —中心像素点 p_c 所对应的灰度值; z —采样像素点 $p_{i+(N/2)}$ 所对应的灰度值。

3.2 PX-LBP 算子

上述 LBP 特征提取算子识别单元多为整幅图像,即每幅图像产生 1 组特征值向量,存在无法识别深度图像内各组成元素的不足,因此本文引入了像素分类。为使经典 LBP 算子适用于像素分类的需要,本文提出了 PX-LBP 算子,主要从以下几个方面对经典 LBP 算子进行了改进:

(1) 将同一邻域所产生 LBP 特征值的数量由原来的 1 个增加到了 K 个。增加方法是通过将起始像素点等角度偏移 $K-1$ 次,对应的偏移角度 $\alpha = \frac{2\pi}{N * K}$ (其中, N —采样点数)。

PX-LBP $^{K=k}$ 的计算公式如下:

$$\text{PX-LBP}^{K=k}(P_c) = \{\text{LBP}_1(P_c), \text{LBP}_2(P_c), \dots, \text{LBP}_{k-1}(P_c), \text{LBP}_k(P_c)\} \quad (7)$$

式中: K —同一邻域内,通过起始点的偏移所产生的 LBP 特征值的数量; P_c —中心像素点的灰度值; $\text{LBP}_1(P_c), \text{LBP}_2(P_c), \dots, \text{LBP}_k(P_c)$ —同一邻域中不同偏移角度下的 LBP 特征值向量。

改进后的 LBP 算子的起始像素点每多偏移一次,就会多产生一个 LBP 特征值,邻域所选点也会变的更加密集;在一定范围内,所产生的特征向量对该邻域信息覆盖的全面性也会更高。

(2) 将同一中心像素点的圆形邻域数由原来的一个增加到了 m 个,即每个中心像素点产生了 m 个同心圆邻域,各同心圆邻域之间的半径分别为: $R_1 = q, R_2 = q^2, \dots, R_m = q^m$ 。另外,又由于邻域像素点 p_i 距离中心像素点 p_c 越远,它对描述 p_c 贡献的信息量越小,因此,本文对 $\text{PX-LBP}^{K=k, M=m}$ 进行了加权,加权系数为: $\omega = \frac{1}{R_j} (j = 1, 2, \dots, m)$ 。

PX-LBP $^{K=k, M=m}$ 的计算公式如下:

$$\text{PX-LBP}^{K=k, M=m}(P_c) = \left\{ \begin{aligned} & \frac{1}{q} * \text{PX-LBP}_1^{K=k}(P_c), \\ & \frac{1}{q^2} * \text{PX-LBP}_2^{K=k}(P_c), \\ & \dots \\ & \frac{1}{q^{m-1}} * \text{PX-LBP}_{m-1}^{K=k}(P_c), \\ & \frac{1}{q^m} * \text{PX-LBP}_m^{K=k}(P_c) \end{aligned} \right\} \quad (8)$$

式中: M —同一中心像素点的圆形邻域数; $\text{PX-LBP}_1^{K=k}(P_c), \text{PX-LBP}_2^{K=k}(P_c), \dots, \text{PX-LBP}_m^{K=k}(P_c)$ —同一中心像素点下,不同邻域所产生的各组 LBP 特征值向量。

改进后的 LBP 算子每增加一个邻域,所产生的 LBP 特征值向量就多一组,覆盖的范围也会增大;在一定范围内,所产生的特征向量对该邻域信息覆盖的全面性也会提高。

(3) 与 CS-LSBP $_{N,R}$ 算子相比, PX-LBP 算子除继承 CS-LSBP $_{N,R}$ 外又加入了 $\text{LBP}_{N,R}^+$ 和 $\text{LBP}_{N,R}^-$ [18], 即:

$$\text{PX-LBP} = \text{LBP}_K = \{\text{LBP}_{N,R}^+, \text{LBP}_{N,R}^-, \text{CS-LSBP}_{N,R}\} \quad (9)$$

其中, $\text{LBP}_{N,R}^+$ 和 $\text{LBP}_{N,R}^-$ 的计算公式如下:

$$\text{LBP}_{N,R}^+ = \sum_{i=0}^{N-1} s(p_i - p_c - T) 2^i, s(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (10)$$

$$\text{LBP}_{N,R}^- = \sum_{i=0}^{N-1} s(p_i - p_c - T) 2^i, s(x) = \begin{cases} 1, & x < 0 \\ 0, & x \geq 0 \end{cases} \quad (11)$$

另外,为了增加算法的鲁棒性,本文对 PX-LBP 进行了归一化处理,即:

$$\frac{\text{PX-LBP}}{\| \text{PX-LBP} \|} \rightarrow \text{PX-LBP} \quad (12)$$

改进后的LBP算子解决了CS-LBP_{N,R}算子无法区分相邻像素点与中心像素点是相等还是大于的情况。当LBP⁺_{N,R} = 0, LBP⁻_{N,R} = 0时,表示邻域像素点与中心像素点相同;当LBP⁺_{N,R} = 1, LBP⁻_{N,R} = 0时,表示邻域像素点大于中心像素点;当LBP⁺_{N,R} = 0, LBP⁻_{N,R} = 1时,表示邻域像素点小于中心像素点。

由式(7-9)组合,可得到一个3 * k * m维的特征向量,也就是特征向量PX-LBP^{K=k, M=m}。与经典LBP算子相比,PX-LBP算子所得特征向量维数更多,对中心像素点的邻域特征覆盖也更全面,为准确的像素分类提供了基础。

4 随机森林分类器

随机森林[19-20]分类器是由多个决策树分类器组成的强分类器,有效避免了决策树分类器常出现的过拟合现象。本文利用OpenCV机器学习库MLL中的随机森林相关算法类构建了随机森林分类器,用于对深度图像中各像素点进行分类。过程如下:首先构建随机森林分类器,将特征提取所得训练集导入分类器中进行训练;然后利用训练好的分类器对待测深度图像的像素点进行分类;最后,输出分类结果为获取像素预测图提供数据。

5 装配过程的识别与监测

本文方法主要用于装配体零件识别和装配过程监测,装配体各零件的识别是完成装配监测的基础。

5.1 装配体零件的识别

在合成模型深度图像时,本文用不同的颜色标记不同的零件,并记录各零件对应的RGB值;然后,用模型深度图像训练随机森林分类器,使用训练好的分类器对待测深度图像进行像素分类,得到对应的像素预测图像;最后,通过分析像素预测图像内各零件的RGB值并与标记图像的RGB值做比对,实现对装配体各零件进行识别的目的。

5.2 装配过程监测

在机械设备装配中,装配体的位置被固定或存在有限的几种位置状态,因此可采用像素预测图像比对的方法进行装配过程监测,具体如下:

将深度相机固定,采集正确装配下装配体的深度图像,并进行特征提取及像素分类,获取正确装配像素预测图像a。在装配工艺监测中,采集装配体的深度图像,同样进行特征提取及像素分类,以获取对应像素预

测图像b。比对像素预测图像b与像素预测图像a每一个像素点,分别计算出像素预测图像b中各零件相对于像素预测图像a的像素重合率q_z和像素减少率q_n,像素重合率q_z和像素减少率q_n的具体定义分别如下:

$$q_z = \frac{n_c}{n_z} \tag{13}$$

式中:n_c—零件P_n分别在像素预测图像a和像素预测图像b中坐标重合的像素点数;n_z—零件P_n在像素预测图像a中所含总像素点数。

$$q_n = \frac{n_a - n_b}{n_a} \tag{14}$$

式中:n_a,n_b—零件P_n分别在像素预测图像a和像素预测图像b中所含像素点数。

像素重合率q_z用于判断装配过程是否出错,像素减少率q_n用于判断装配过程出错的类型。具体如下:当某零件的q_z远小于1而q_n远大于0时,即该零件的像素点重合率较低且像素点数差距较大,基本可判断该零件漏装;当某零件q_z远小于1而q_n的绝对值接近于0时,即该零件的像素点重合率较低,但像素点数变化不大,可判断该零件错位。

6 实验及结果分析

本文以双级圆柱圆锥减速器为例进行装配监测实验。使用SolidWorks进行了建模,在Mutigen Creator软件中标记零件颜色。

各零件被标记颜色的RGB值如图2所示。

标号	零件	RGB 值
P0	齿轮轴	140, 140, 140
P1	大齿轮	49, 49, 49
P2	底座	102, 102, 102
P3	斜齿轮 1	146, 146, 146
P4	斜齿轮 2	139, 139, 139
P5	轴 1	51, 51, 51
P6	轴 2	175, 175, 175
P7	大轴承	186, 186, 186
P8	端盖 1	144, 144, 144
P9	端盖 2	179, 179, 179
P10	端盖 3	136, 136, 136
P11	端盖 4	166, 166, 166
P12	中轴承	181, 181, 181
P13	轴套	90, 90, 90




图2 减速器各零件的颜色标记

实验环境配置如下:计算机: Intel® Xeon(R) CPU E5-2630 V4 @ 2.20GHz x 20, 64G 内存, UBUNTU 16.04 LTS 系统;深度图像获取传感器为 Kinect2.0;编

译环境: GCC 编译器。

6.1 相关参数的确定

由于算法所涉及的参数较多,本文仅介绍部分关键参数的确定过程,如:同一邻域起始像素点数 K ,同一中心像素点的圆形邻域数 m 和圆形邻域半径之间的公比 q 。

在实验中,训练集使用 290 张模型的合成深度图




图3 部分参数的确定

由图3(a)可得:随着起始像素点数 K 的增大,像素分类准确率先快速增大,在 2 后开始增长缓慢,尽管后面的准确率还在缓慢上升,但考虑到 K 值对识别效率影响较大,因此本文确定同一邻域内起始像素点数 K 为 2。由图3(b)可得:随着单个中心像素点圆形邻域个数 m 的增大,像素分类准确率先快速上升,大约在 22 处后开始浮动,因此本文确定 m 值为 22。由图3(c)可得:随着圆形邻域半径公比 q 的增大,像素分类准确率先快速上升,大约在 4.0 处后开始浮动,因此确定 m 的值为 4.0。

其他主要参数确定如下:邻域 Ω 的边长确定为 2,邻域采集点数 P 确定为 16,训练图片张数确定为 290,在随机森林中,树的最大深度设置为 23,最小样本数设置为 5,树的最大数量设置为 50,准确率设置为 0.006 f ,终止判断条件设置为以树的数目或准确率为终止条件。

6.2 识别效率

由于装配过程监测有实时性要求,即算法的识别效率将直接影响整个装配过程的时间和成本,故本文方法所需时间主要集中于特征提取及像素分类两部分。本文设计了两组实验,实验中训练集和测试集与 6.1 完全相同,记录平均识别时间,结果如表 1 所示。

像,测试集分为两类:10 张模型的合成深度图像组成的合成测试集,10 张实物的真实深度图像组成的真实测试集。像素点采集方式:训练集采用横纵坐标均匀采集像素点的方式,测试集则采用随机选点的方式,每个深度图像中随机选取 2 000 个像素点进行特征提取。

实验数据如图 3 所示。

表 1 识别单张图片所用时间

	合成测试集/ms	真实测试集/ms
特征提取	18 796	22 301
像素分类	298	277
总时间	19 094	22 578

由表 1 可得:在深度图像像素点采集方式为逐点采集的情况下,每张模型深度图像从采集到完成识别大约需要 19 s,每张真实装配体深度图像从采集到完成识别大约需要 22 s。单纯从表 1 中的单张图片识别时间上看,该方法实时性不高,但在实际应用中,对于一些简单的装配体深度图像,可适当减少像素点的采集量,从而缩短特征提取时间。

6.3 装配体各零件像素识别

为了获取该方法对装配体各零件的像素识别率,本文设计了两组实验,实验中训练集和测试集同 6.1 完全相同,实验结果如图 4 所示(横坐标的零件标号具体意义可参考图 2)。

由图 4 可得:本文对于合成测试集的平均像素识别率可达到 98.81%,而对于真实测试集,由于 Kinect 深度图像采集精度的影响,平均像素识别率为 77.51%,少数小件由于被遮挡、像素较少的缘故像素识别率略低。

经分类器分类后的深度图像及对应的像素预测图像如图 5 所示。




图4 分类器对各零件的像素识别率




图5 深度图像(左)和像素预测图像(右)

6.4 装配过程的监测

本文方法通过对比正确装配体的像素预测图像与待测装配体的像素预测图像,图像如图6所示。

计算两者的像素重合率 q_z 和像素减少率 q_n ,可以推断待测装配体的装配情况,下面以图6为例详细分析这一过程。




图6 正确装配像素预测图像(左)和待测像素预测图像(右)

案例一:待测深度图像为模型的合成深度图,待测深度图中 P_7 件漏装。经特征提取及像素分类后获得像素预测图像如图6(a)所示:左为正确装配的像素预测图像,右为出现 P_7 件漏装的像素预测图像。根据式(13,14)分别计算两者的像素重合率 q_z 和像素减少率 q_n ,结果如表2所示。

表2 P_7 件漏装的比对数据

零件标号	像素重合率 $q_z / (\%)$	像素减少率 $q_n / (\%)$
P_0	99.74	0.013
P_1	100	-0.006
P_2	100	-0.022
P_3	100	0
P_4	100	-0.005
P_5	100	0
P_6	99.79	-0.042
P_7	15.67	0.843
P_8	100	-0.018
P_9	96.99	-0.052
P_{10}	100	-0.153
P_{11}	100	-0.008
P_{12}	100	0
P_{13}	100	-0.004

分析表2的比对数据:首先分析各件的像素重合率, P_7 件重合率较低,可推断该件可能存在装配错误;然后,分析各件的像素减少率, P_7 件的像素减少率偏高;因此基本可判断 P_7 件出现了漏装现象。

案例二:待测深度图像为实物的真实深度图,待测深度图像中 P_3 件漏装。经特征提取及像素分类后获得像素预测图像如图6(b)所示:左为正确装配的像素预测图像,右为出现 P_3 件漏装的像素预测图像。同上,分别计算两者的像素重合率 q_z 和像素减少率 q_n ,结果如表3所示。

表 3 P_3 件漏装的比对数据

零件标号	像素重合率 $q_2/(%)$	像素减少率 $q_n/(%)$
P_0	81.58	-0.081
P_1	99.32	-0.118
P_2	100	0.033
P_3	23.88	0.758
P_4	94.63	0.083
P_5	80.19	0.217
P_6	93.01	0.079
P_7	66.90	0.028
P_8	98.09	-0.157
P_9	98.90	-0.241
P_{10}	99.28	-0.057
P_{11}	99.43	-0.063
P_{12}	73.25	0.102
P_{13}	97.74	-0.167

分析表 3 的比对数据:首先分析各件的像素重合率, P_3 件重合率较低,可推断该件可能存在装配错误;然后,分析各件的像素减少率, P_3 件的像素减少率偏高;因此基本可判断 P_3 件出现了漏装现象。

案例三:待测深度图像为模型的合成深度图,待测深度图像中 P_0 件装配错位。经特征提取及像素分类获得像素预测图像如图 6(c) 所示:左为正确装配的像素预测图像,右为出现 P_0 件错位的像素预测图像。同上,分别计算两者的像素重合率 q_2 和像素减少率 q_n ,结果如表 4 所示。

表 4 P_0 件错位的比对数据

零件标号	像素重合率 $q_2/(%)$	像素减少率 $q_n/(%)$
P_0	72.21	0.144 4
P_1	99.82	-0.005
P_2	100	-0.021
P_3	99.55	0
P_4	100	0
P_5	80.19	0.033
P_6	99.38	0.004
P_7	99.52	0
P_8	98.74	0.010
P_9	100	0
P_{10}	100	0.005
P_{11}	97.67	0
P_{12}	93.72	0.099
P_{13}	99.61	0.001

分析表 4 的比对数据:首先分析各件的像素重合率, P_0 件重合率相对偏低,可推断该件可能存在装配错误;然后,分析各件的像素减少率, P_0 件的像素减少率与其他件相比虽然偏高,但差距不大;因此可判断 P_0 件出现了错位现象。

7 结束语

针对机械产品装配维修诱导中零件和装配体的识别、监测问题,本文提出了基于 PX-LBP 和像素分类的装配体零件识别方法;将 LBP 算法应用于像素分类,提出了 PX-LBP 特征提取算子,使 LBP 算子更好地与像素分类相融合。

本文提出的装配体零件识别方法对于模型深度图像的像素识别率达到 98.81%,对于真实装配体深度图像的像素识别率达到 77.51%。本文利用像素分类获取像素预测图,通过对比像素预测图,完成了装配体各零件的识别及装配过程的监测。

基于 PX-LBP 和像素分类的装配体零件识别方法对其他领域的物体识别同样具有一定的参考价值。

参考文献 (References):

- [1] CAO W, JIANG P Y, LU P, et al. Real-time data-driven monitoring in job-shop floor based on radio frequency identification [J]. **The International Journal of Advanced Manufacturing Technology**, 2017,92(5-8):2099-2120.
- [2] YIN C H, WANG W, ZHAO G, et al. Research on rapid layout method of RFID devices for aircraft assembly monitoring [C]. Proceedings of 2016 6th International Conference on Information Technology for Manufacturing Systems, Prague:IEEE,2016.
- [3] 周 铨. 一种过盈压装装配工序的过程监测系统[J]. 机电产品开发与创新,2018,31(3):84-86.
- [4] 陈 培,申红明,张会猛,等. 基于 ARM 的线缆生产监控系统的设计[J]. 现代电子技术,2017,40(8):65-72.
- [5] 汪嘉杰,王 磊,范秀敏,等. 基于视觉的航天电连接器的智能识别与装配引导[J]. 计算机集成制造系统,2017,23(11):2423-2430.
- [6] OJALA T, PIETIKAINEN M, HARWOOD D. A comparative study of texture measures with classification based on featured distributions [J]. **Pattern Recognition**, 1996,29(1):51-59.
- [7] OJALA T, PIETIKAINEN M, MEMBER S, et al. Multires-

- olution gray-scale and rotation invariant texture classification with local binary patterns [J]. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2002, 24 (7): 971-987.
- [8] LIAO S, ZHU X, LEI Z, et al. Learning multi-scale block local binary patterns for face recognition [J]. **Lecture Notes in Computer Science**, 2007(4642): 828-837.
- [9] HEIKKILA M, PIETIKAINEN M, SCHMID C. Description of interest points with local binary patterns [J]. **Pattern Recognition**, 2009, 42(3): 425-436.
- [10] MATURANA D, MERY D, SOTO A. Learning discriminative local binary patterns for face recognition [C]. **IEEE international conference on automatic face and gesture recognition**, Santa Barbona: IEEE, 2011.
- [11] HUSSAIN S U, NAPOLEON T, JURIE F. Face recognition using local quantized patterns [C]. **British machine vision conference**, Guildford: IEEE, 2012.
- [12] 冀中, 聂林红. 基于抗噪声局部二值模式的纹理图像分类 [J]. **计算机研究与发展**, 2016, 53(5): 1128-1135.
- [13] 胡敏, 腾文娣, 王晓华, 等. 融合局部纹理和形状的人脸表情识别 [J]. **电子与信息学报**, 2018, 40(6): 1338-1344.
- [14] SHOTTON J, FITZGIBBON A, COOK M, et al. Real-time human pose recognition in parts from single depth images [J]. **Computer Vision & Pattern Recognition**, 2011, 56(1): 1297-1304.
- [15] 田野, 项世军. 基于LBP和多层DCT的人脸活体检测算法 [J]. **计算机研究展**, 2018, 55(3): 1128-1135.
- [16] 李光梅, 苟岩岩, 刘果玲, 等. 易拉罐空罐缺陷智能检测系统的设计 [J]. **包装与食品机械**, 2017(6): 33-36.
- [17] 刘继忠, 吴文虎, 程乘, 等. 基于像素滤波和中值滤波的深度图像修复方法 [J]. **光电子·激光**, 2018, 29(5): 539-544.
- [18] XU J, DING X Q, WANG S J, et al. Background subtraction based on combination of texture, color and intensity [J]. **ICSP: 2008 9th International Conference on Signal Processing**, 2008(1): 1400-1405.
- [19] BREIMAN L. Randomized decision forests [J]. **Machine Learning**, 2001, 45(1): 5-32.
- [20] BREIMAN L, FRIEDMAN J H, OLSHEN R A, et al. Classification and regression trees (CART) [J]. **Biometrics**, 1984, 40(3): 358.

[编辑: 张 豪]

本文引用格式:

田中可, 陈成军, 李东年, 等. 基于PX-LBP和像素分类的装配体零件识别研究 [J]. **机电工程**, 2019, 36(3): 236-243.

TIAN Zhong-ke, CHEN Cheng-jun, LI Dong-nian, et al. Recognition of assembly parts based on PX-LBP and pixel classification [J]. **Journal of Mechanical & Electrical Engineering**, 2019, 36(3): 236-243.

《机电工程》杂志: <http://www.meem.com.cn>