

DOI: 10.13382/j.jemi.B2408013

# 基于智能形状匹配的零件全尺寸在线视觉检测方法<sup>\*</sup>

许桢英<sup>1</sup> 杨为涛<sup>1</sup> 雷英俊<sup>1,2,3</sup> 刘鑫<sup>1</sup> 沙之洵<sup>1</sup>  
(1. 江苏大学机械工程学院 镇江 212000; 2. 东南大学仪器科学与工程学院 南京 210096;  
3. 苏州超锐微电子有限公司 苏州 215004)

**摘要:**针对传统视觉方法在测量不同工件全尺寸时的局限性,提出了一种基于形状匹配的工件全尺寸在线检测方法。该方法通过将目标工件图像输入到改进的 Superpoint 关键点检测网络,得到所有关键点,并利用关键点实现工件轮廓的描述;然后将关键点模板与目标工件的关键点一起输入点渲染层,使用增强关键点位置信息的 Superglue 特征全匹配算法,提取与模板点匹配的关键点,以及关键点之间的距离,实现工件的全尺寸测量。为了验证方法的有效性,分别进行了量块尺寸检测实验,标定板尺寸检测实验和原电池尺寸检测实验,实验结果表明,对于 25 mm 零级量块(精度优于 $\pm 0.14\text{ }\mu\text{m}$ )的尺寸检测实验,系统十次重复测量结果的最大偏差为 $\pm 0.02\text{ mm}$ ,标准差为 $0.01\text{ mm}$ ,表明系统具有较高的重复性精度;对于棋盘格标定板,尺寸测量误差不超过 $\pm 0.03\text{ mm}$ ,验证了该方法的可行性;在原电池的尺寸测量实验中,七号电池尺寸检测的误差范围为 $\pm 0.03\text{ mm}$ ,平均耗时为 $0.08\text{ s}$ ,五号电池的尺寸检测误差为 $\pm 0.03\text{ mm}$ ,平均耗时为 $0.09\text{ s}$ ,均能够满足该企业原电池产线生产过程中,在线检测的 $\pm 0.05\text{ mm}$ 精度要求和 $0.1\text{ s}$ 的实时性检测要求。相比于传统算法需要针对不同工件采用不同的检测算法,所提出的方法能够有效适应不同工件的尺寸检测需求,并可广泛应用于工业现场的零件在线全尺寸检测。

**关键词:** 关键点检测;特征匹配;在线尺寸检测;全尺寸

**中图分类号:** TP391;TN247      **文献标识码:** A      **国家标准学科分类代码:** 520.2060

## Online vision-based full dimensional inspection method for parts based on intelligent shape matching

Xu Zhenying<sup>1</sup> Yang Weitao<sup>1</sup> Lei Yingjun<sup>1,2,3</sup> Liu Xin<sup>1</sup> Sha Zhixun<sup>1</sup>  
(1. School of Mechanical Engineering, Jiangsu University, Zhenjiang 212000, China; 2. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China; 3. Suzhou Chaorui Microelectronics Co., Ltd, Suzhou 215004, China)

**Abstract:** To address the limitations of traditional vision-based methods in measuring the full dimensions of different workpieces, this paper proposes an online full-dimension inspection method for workpieces based on shape matching. The method inputs the target workpiece image into an improved Superpoint keypoint detection network to obtain all keypoints, which are then used to describe the workpiece contour. Then, the keypoint template and the keypoints of the target workpiece are fed into a point rendering layer. An enhanced Superglue feature matching algorithm with augmented keypoint location information is employed to achieve full matching, extracting keypoints that match the template points and measuring the distances between keypoints, thereby enabling full-dimension measurement of the workpiece. To validate the effectiveness of the proposed method, experiments were conducted, including gauge block size detection, calibration plate size detection, and electrochemical cell size detection. The experimental results indicate that for the size measurement experiment of a 25 mm Grade 0 gauge block (with an accuracy better than  $\pm 0.14\text{ }\mu\text{m}$ ), the maximum deviation of the system's ten repeated measurements was  $\pm 0.02\text{ mm}$ , and the standard deviation was  $0.01\text{ mm}$ , demonstrating that the system has high repeatability accuracy. For the checkerboard calibration plate, the size measurement error does not exceed  $\pm 0.03\text{ mm}$ , verifying the feasibility of the proposed method. In the dimensional measurement experiment of primary batteries, the AAA battery size inspection had an error range of  $\pm 0.03\text{ mm}$  with an average processing time of  $0.08\text{ s}$ , while the AA battery inspection showed an error of  $\pm 0.03\text{ mm}$

with an average time of 0.09 s. Both meet the enterprise's production line requirements for online inspection, which demand  $\pm 0.05$  mm accuracy and real-time detection within 0.1 s. Unlike traditional algorithms that require specific detection methods for different workpieces, the proposed approach exhibits strong adaptability to diverse dimensional detection requirements and is highly applicable for online full-size inspection of parts in industrial settings.

**Keywords:** keypoint detection; feature matching; online dimensional inspection; full dimensional inspection

## 0 引 言

在现代制造业中,工件尺寸检测作为质量控制和调控产品工艺的重要手段,在产品生产过程中发挥着不可或缺的作用。随着工业自动化和智能制造的不断发展,产线的自动化程度和生产速度也在不断提升,以人工和接触式测量为主的传统尺寸检测方法极大地限制了生产的效率<sup>[1]</sup>。

随着数字图像处理技术的发展,基于机器视觉的尺寸测量方法因其精度高、速度快、非接触测量等特点受到了广泛应用<sup>[2]</sup>。赵朝朝等<sup>[3]</sup>提出了一种改进 Canny 算子下的工件尺寸测量方法,在检测到工件边缘后,通过主成分分析方法(PCA)计算出工件方向,并根据轮廓点的投影和相机标定系数计算出工件的实际尺寸,但是该方法只能检测出工件的长边和短边尺寸,算法检测误差约为 $\pm 2$  mm。李小宝等<sup>[4]</sup>提出了一种改进的自适应阈值 Canny 算法,通过最小二乘法拟合边界直线,图像矫正后,利用固定的图像切割比,实现对电子束接头区域,线束区域和主体区域的分割,并选取拟合边界上的中点作为尺寸测量点,串行实现电子束产品的尺寸检测,检测误差 $\pm 0.1$  mm 以内,平均检测耗时在 1 s 以内。李晋鑫等<sup>[5]</sup>提出了一种基于机器视觉的内丝接头凹槽尺寸测量系统,首先利用固定阈值分割出工件,并利用双边滤波联合 Roberts 算子提取工件边缘,最后通过最小二乘法拟合实现尺寸的检测,测量精度为 $\pm 0.01$  mm,平均检测时间为 0.37 s。在传统尺寸检测方法中,往往只能实现工件长和宽的测量,而对于工件局部的尺寸测量,一般是采用固定的图像处理步骤,基于固定的阈值分割或者固定的图片比例分割。

基于传统视觉的尺寸检测方法,因为测量工件全尺寸的局限性以及抗干扰性差等缺点,难以适应逐渐多样化的工件形状和日益复杂的工业场景。相比之下,深度学习方法以其独特的优势正在迅速成为工业生产过程中检测领域的主流方案<sup>[6]</sup>。李帅等<sup>[7]</sup>提出了一种基于深度学习的柠檬尺寸自动检测方法,通过改进的 RCF 网络获取更好的柠檬图像边缘,再利用 OpenCV 的阈值-面积算法获取柠檬尺寸。戴先鑫等<sup>[8]</sup>利用 YOLOv5 目标检测算法实现螺栓区域的截取,并利用改进的 Canny 边缘检测算法对截取区域进行检测,获取螺栓的轮廓信息,最后采

用霍夫两直线之间最短距离实现螺栓直径的测量,对不同类型螺栓直径的检测误差率在 5.5% 以内。孙小龙<sup>[9]</sup>设计了一种基于深度学习的贝类海产品尺寸检测系统,首先利用编/解码模式实现贝类海产品的图像分割,之后再利用最小外接矩形框计算出贝类海产品的长度和宽度。综上可知,在目前的尺寸检测任务中,深度学习的方法往往是用于边缘检测或目标区域的定位。

传统的尺寸测量方法往往是利用 Canny、Sobel 和 Roberts 等边缘检测算子,通过分析图像中像素强度的显著变化来提取物体的轮廓,进而以边缘点的集合作为物体形状信息的表达<sup>[10]</sup>。而目前尺寸检测方面的深度学习算法大多是用于边缘检测或目标区域的定位,并没有改变传统尺寸检测的方式。使用边缘点集合的方式实现对工件的形状信息描述时,不仅存在数据量较大,在处理一些复杂形状或者高分辨率图像时,计算和储存成本较高的问题,而且边缘点集合的表达方式缺乏对工件整体结构的抽象描述,难以直接用于高效的形状匹配或识别任务。此外,研究者们往往针对一种工件的尺寸进行研究,例如针对机动车外廓尺寸的测量<sup>[11]</sup>,针对螺纹关键参数的测量<sup>[12]</sup>等,分别由不同的研究者使用不同的算法实现。

因此,本文针对目前尺寸检测方法存在的问题,提出了一种基于形状匹配的全尺寸在线检测方法,与传统的尺寸方法不同,本文不再依赖于密集的边缘点集合,而是通过提取物体的几个关键点来实现对其轮廓信息的描述,并利用点渲染层,给关键点附加属性,利用关键点之间的距离实现工件的全尺寸测量。基于形状匹配的尺寸检测方法,使用自监督的检测网络,对于不同的工件尺寸检测不需要重新训练<sup>[13]</sup>,只需要将待检测工件的模板添加到检测库中,不仅可以实现对于多种工件的全尺寸测量,而且通过工件的关键点去计算尺寸的方法,具有较强的泛化性和抗干扰能力。

## 1 方法

基于形状匹配的工件全尺寸在线检测方法,检测过程主要有 3 步:首先,通过轻量化关键点检测模型,实现工件关键点及描述符的检测,并将检测结果和工件设定的模板关键点一起输入到点渲染层中;之后,通过图注意力增强匹配描述符,并利用最优匹配方法,筛选出待检测

工件中与模板中点的特征对应的关键点;最后,根据检测到的工件关键点,实现尺寸的测量。算法检测流程如图 1 所示。

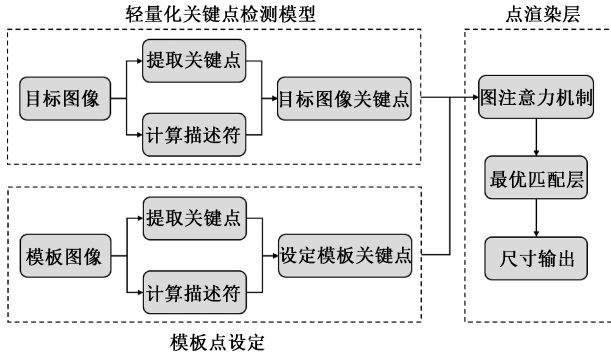


图 1 尺寸检测流程

Fig. 1 Dimension inspection process

### 1.1 轻量化关键点检测网络

为了更好地满足工业生产中的快速检测需求,通过对比多种关键点检测算法,本文选择了 Superpoint 关键点检测网络,并对其进行修改,通过引入深度可分离卷积,调整网络结构,并加入 ECA 注意力机制,使得网络在基本不损失检测精度的情况下,较大程度上减小了网络的参数量和计算量。

Superpoint 是一种自监督网络框架,网络编码层采用 VGG 架构<sup>[14]</sup>,由卷积层、池化层和非线性激活层组成。网络结构和语义分割网络类似,由公共的编码器和独立的关键点解码网络和描述符解码网络组成<sup>[15]</sup>。Superpoint 网络整体架构如图 1 所示。对于网络共享的编码器,一共使用了 8 个 padding 为 1, stride 为 1, 卷积核为  $3 \times 3$  的卷积层,每个卷积层后使用 ReLU 非线性激活函数,并分别在第 2、4、6 次激活函数后进行一次下采样,下采样使用  $2 \times 2$  的最大池化,编码器最终输出的 feature map 大小为输入图片的  $1/8$ 。用  $H$ 、 $W$  表示输入图片的尺寸,对于输入图片  $I \in R^{H \times W}$ ,经过网络共享的 Encoder 后,网络输出 feature map 为  $M \in R^{H_c \times W_c \times 128}$ ,其中  $H_c = H/8$ ,  $W_c = W/8$ ,并将网络输出分别传递给独立的关键点解码器和描述符解码器。在关键点解码器和描述符解码器中,对于输入的 feature map,具体为  $M \in R^{H_c \times H_c \times 128}$ ,都是首先经过一次卷积,将维度从 128 升到 256。对于关键点解码器,通过再次卷积,生成特征响应图  $X \in R^{H_c \times H_c \times 65}$ ,通过 Softmax 除去这 65 个通道中一个没有特征点的 dustbin,余下的特征响应图在平面位置  $(h, w)$  上的特征向量  $X_{hw}$  映射回原图是一个  $8 \times 8$  的区域,通过 Reshape 将图像恢复成尺寸为  $H \times W$  的特征点概率图,每一个关键点对应一个置信度  $scores_i$ 。对于描述符解码器,在将维度升到 256 后,得到张量  $D \in R^{H_c \times W_c \times 256}$ ,通过双三次插值

和 L2 范数正则化,输出的描述符特征图为  $B \in R^{W \times H \times 256}$ 。根据关键点解码器中输出的关键点坐标,每个关键点都有一个 256 维度的描述符。

Superpoint 网络是使用自监督方式进行训练,主要训练过程分为 3 个步骤。1) 将只包含编码器和关键解码器的网络称为 Magicpoint 网络,基于点和线生成虚拟数据集 Synthetic Shapes,将三角形、棋盘格、立方体等,其角点视为特征点作为正样本,椭圆和高斯噪声无特征点作为负样本,训练 Magicpoint 网络。为了更好的适应工件尺寸检测,本文在虚拟数据集中,加入了直线曲线相交数据集,将直曲线交点作为特征点,加入到 Magicpoint 网络训练过程中;2) 使用训练后的 Magicpoint 网络对真实图片进行预测,为了增强网络的特征点提取能力,将真实图片和  $N$  张经过单应性变换后的真实图片输入到 Magicpoint 网络中,得到  $N+1$  张 heatmap 图,将其中  $N$  张经过单应性变换后的 heatmap 经过单应性逆变换后与真实图片的 heatmap 累加在一起,并通过阈值截取后获得图像的真实关键点,获得真实图像数据集;3) 用该真实图像数据集训练 Superpoint 网络,并使用单应性变换,生成最终的特征点及描述符检测网络。本文使用 COCO2017 数据集作为真实图像数据。

本文轻量化关键点检测网络的损失函数与 Superpoint 网络的损失函数保持一致,需要考虑上半部分的特征点损失  $L_p$  和下半部分的描述符损失  $L_d$ ,并使用超参数  $\lambda$  来平衡这两个损失,如式(1)所示。

$$L(X, X', D, D', Y, Y', S) = L_p(X, Y) + L_p(X', Y') + \lambda L_d(D, D', S) \quad (1)$$

式中:  $X$ 、 $D$ 、 $Y$  表示将原图输入到 Superpoint 网络后输出的特征点概率图,描述子特征图和原图特征点的标签值;  $X'$ 、 $D'$ 、 $Y'$  为原图经过单应性变换后输入到 Superpoint 网络后得到的输出,含义和  $X$ 、 $D$ 、 $Y$  相同。

对于特征点损失函数  $L_p$ ,采用交叉熵损失函数,公式如下:

$$L_p(X, Y) = \frac{1}{H_c W_c} \sum_{h=1}^{H_c} \sum_{w=1}^{W_c} l_p(x_{hw}, y_{hw}) \quad (2)$$

式中:  $x_{hw}$ 、 $y_{hw}$  分别表示  $X$ 、 $Y$  在坐标  $(h, w)$  处的值。 $l_p$  计算公式如下:

$$l_p(x_{hw}; y) = -\lg \left( \frac{\exp(x_{hy})}{\sum_{k=1}^{65} \exp(x_{huk})} \right) \quad (3)$$

其中,  $l_p$  需满足的条件为,使得  $x_{hw}$  在标签  $y$  对应的通道上尽可能大。 $x_{huk}$  代表  $X$  在第  $k$  个通道中,在坐标  $(h, w)$  处的值,每一个  $x_{huk}$  对应输入图片中一个  $8 \times 8$  像素点的图片区域。

对于描述符损失函数  $L_d$ ,公式如下:

$$L_d(D, D', S) = \frac{1}{(H_c W_c)^2} \sum_{h=1}^{H_c} \sum_{w=1}^{W_c} l_d(d_{hw}; d'_{h'w'}; s_{hwh'w'}) \quad (4)$$

式中:  $d_{hw}$ 、 $d'_{h'w'}$  分别表示  $D$ 、 $D'$  在  $(h, w)$ 、 $(h', w')$  处的值,  $l_d$  为合页损失函数, 用于确保最后解的稀疏性。  $l_d$  计算公式如下:

$$l_d(d; d'; s) = \lambda_d \cdot s \cdot \max(0, m_p - d^T d') + (1 - s) \cdot \max(0, d^T d' - m_n) \quad (5)$$

其中, 使用超参数  $\lambda_d$  来平衡描述符内部正向对应损失和负向对应损失值, 使用  $m_p$  和  $m_n$  来限制正负方向上的阈值。

同时, 指示函数  $s_{hwh'w'}$  用来判断  $d_{hw}$  和  $d'_{h'w'}$  在原图中对应的位置是否相近, 公式如下:

$$s_{hwh'w'} = \begin{cases} 1, & \|H_{p_{hw}} - p_{h'w'}\| < 8 \\ 0, & \text{其他} \end{cases} \quad (6)$$

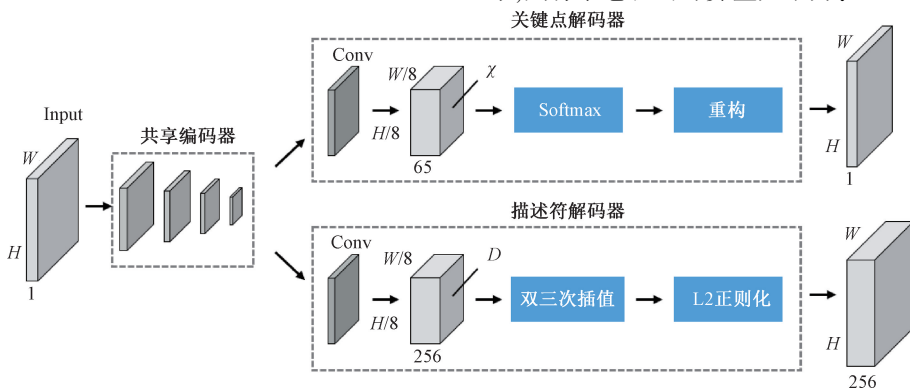


图2 Superpoint 网络框架

Fig. 2 Superpoint network framework

$$F = H \times W \times D \times D \times N \times M \quad (7)$$

深度可分离卷积过程中, 深度卷积对每个输入通道单独进行  $D \times D$  的卷积, 计算量为:

$$F = H \times W \times D \times D \times N \quad (8)$$

逐点卷积对深度卷积的输出进行  $1 \times 1$  卷积, 用于通道混合, 计算量为:

$$F_s = H \times W \times N \times M \quad (9)$$

所以, 将标准卷积分解为深度卷积和逐点卷积后, 计算量减小比为:

$$\frac{F_w + F_s}{F} = \frac{1}{M} + \frac{1}{D^2} \quad (10)$$

对于模型的存储需求和训练复杂度的影响, 标准卷积的参数量为  $D \times D \times N \times M$ , 深度卷积的参数量为  $D \times D \times N$ , 逐点卷积的参数量为  $N \times M$ , 所以标准卷积和被分解为深度卷积和逐点卷积的参数量减少比结果亦为  $1/M + 1/D^2$ 。

式中:  $p_{hw}$  和  $p_{h'w'}$  分别表示  $d_{hw}$  和  $d'_{h'w'}$  对应的图片单元的位置中心坐标;  $H_{p_{hw}}$  是将  $p_{h'w'}$  进行与原图相同的单应性变换后得到的结果。因为在共享编码层处采用了8倍下采样, 所以  $H_{p_{hw}}$  和  $p_{h'w'}$  之间的距离小于8个像素差则可以认为是一个正确的匹配, 对应到原图上则是相差一个像素。

为了提升 Superpoint 模型的检测速度, 使其满足工业上用于实时尺寸检测的需求, 本文对网络模型进行了如下改进。

1) 引入了深度可分离卷积, 将共享编码层、关键点解码层和描述符解码层中的标准卷积分解为深度卷积和逐点卷积, 大大减少网络的参数数量、计算量和模型大小<sup>[16]</sup>。对于模型推理时间和运行时计算需求的影响, 假设输入特征图的尺寸为  $H \times W$ , 输入通道数为  $N$ , 卷积核尺寸为  $D \times D$ , 输出通道数为  $M$ , 若不改变输入图像尺寸, 则标准卷积的计算量大小为:

关键点解码器

描述符解码器

因此, 若网络使用的卷积核尺寸为  $3 \times 3$ , 即  $D = 3$ , 那么深度可分离卷积的计算量和参数量约为标准卷积  $1/9$ , 大大加快了网络的推理速度, 减小了存储需求和训练复杂度。

2) 在每层的激活函数后加入归一化层, 增强网络的稳定性和泛化能力<sup>[17]</sup>, 并将在共享编码器中卷积+池化的下采样方式改为使用步长为2的深度可分离卷积, 去除池化操作, 通过增加卷积过程中的步长, 实现图像的下采样。

3) 将关键点解码层和描述符解码层中, 相同的第1个升维卷积层提前到共享编码器中, 并将共享编码器总层数更改为7层卷积, 且第2、4、6层卷积的步长为2, 网络输出通道数依次为  $[64, 64, 64, 128, 128, 128, 256]$ 。修改后的 Superpoint 网络结构如表1所示, 其中每一层代表一次卷积操作, 其中第1个数字代表输入通道大小,  $3 \times 3$  表示卷积核大小, 最后一个数字表示输出通道大小, “+下采样”表示卷积步长为2。最终通过共享编码器的处理, 输出特征图大小为原图的  $1/8$ <sup>[18]</sup>。



表 1 Superpoint 网络结构

Table 1 Superpoint network architecture

| 共享编码器           | 关键点解码器     | 描述子解码器      |
|-----------------|------------|-------------|
| 1×3×3×64        | 256×1×1×65 | 256×1×1×256 |
| 64×3×3×64+下采样   | —          | —           |
| 64×3×3×64       | —          | —           |
| 64×3×3×64+下采样   | —          | —           |
| 64×3×3×128      | —          | —           |
| 128×3×3×128+下采样 | —          | —           |
| 128×3×3×256     | —          | —           |

4) 为了弥补上述操作对模型检测准确率的影响,本文在共享编码器中加入了 ECA 注意力机制。在深度卷积神经网络中,通道注意力机制的主要作用是通过对特征图的通道维度进行加权来增强网络对重要特征的关 注,同时抑制不重要的通道信息<sup>[19]</sup>。通道注意力通过动态地调整每个通道的权重,提升模型对关键特征的表示能力。ECA 注意力机制认为传统的 SENet 注意力机制中的全连接降维方式会对通道注意力机制带来负面影响,并且试图捕捉所有通道之间的相关性会降低模型推理效率<sup>[20]</sup>。ECA 通过快速的一维卷积来捕捉局部的通道间关系,从而有效地减少了参数数量和计算开销,注意力结构如图 3 所示。对于输入的特征,首先进行全局平均池化,将尺寸为  $C \times W \times H$  的输入特征图转化为为  $1 \times 1 \times C$  的一维通道特征向量,之后通过 2 个局部交互的全链接层以捕捉通道间的关系。随后,经过 Sigmoid 非线性激活函数生成通道权重,最后将获取到的通道注意力权重加 权到输入特征图中,突出通道间重要特征,抑制次要特征。




图 3 ECA 注意力机制结构

Fig. 3 Structure of ECA attention mechanism

1.2 点的渲染

通过 Superpoint 关键点检测网络后,输出描述符中只携带点的坐标及特征,并不涉及明显的尺寸信息,因此需要在众多关键像素点中,选取到携带尺寸信息的关键点是本文的下一个目标。受特征匹配算法的启发<sup>[21]</sup>,当检测工件尺寸时,本文将一张模板工件图片输入到关键点检测网络中,得到图片的关键点信息,并人工在其中选出可用于尺寸计算的关键点作为模板关键点,并对这些模板关键点进行编号,作为点的附加属性。对于一种工件的尺寸检测,此过程只需进行一次,用于获取一张该工件关键点的模板。之后,待检测的工件图像经过关键点检测网络后,得到该工件的所有关键点,通过将这些关键点与模板关键点进行特征匹配,将待检测图像中,在模板点中有对应特征匹配的关键点置为 1,在模板点中无对应特征匹配的点位为 0,筛选出待检测图像中包含尺寸信息的关键点。本文将筛选出与模板点对应的工件关键点的过程称之为点的渲染<sup>[22]</sup>。通过筛选出的带有编号的特征点,利用点之间的距离,可以实现工件全尺寸的检测。

在 Superglue 特征匹配网络的基础上,本文的点渲染方法将模板图像的关键点信息  $p_i^A$  及其描述符  $d_i^A$ ,以及目标图像的关键点信息  $p_i^B$  及其描述符  $d_i^B$  作为输入,并将特征匹配问题转为最优传输问题求解。算法处理流程如图 4 所示。总体分为两个框架, GNN ( graph attention networks) 注意力机制和最优匹配层<sup>[23]</sup>。首先 GNN 注意力机制通过两个策略来实现描述符的强化,一种是通过在描述符中加入特征点位置信息,整合更多的上下文线索,另一种是使用交替的交叉注意力和自我注意力层来解决歧义。之后的最优匹配层用于求解匹配描述符内积,创建一个  $M \times N$  矩阵并对其进行扩展,之后利用 Sinkhorn 算法找到模板点的最佳分配<sup>[24]</sup>,实现模板点和特征点的配准,完成关键点的渲染。

1) 全匹配任务

Superglue 用于特征点匹配时,考虑到实际应用场景中的遮挡问题,某些源图像中的关键点可能在目标图像中找不到匹配,或者目标图像中的某些点在源图像中没




图 4 点渲染网络结构

Fig. 4 Point render network structure

有对应的关键点,因此采用了部分匹配的逻辑,对部分的关键点匹配对进行赋值,而允许未匹配的关键点存在。但当其用于本文的关键点渲染时,部分匹配的逻辑已不再适用。因此,本文将其修改为一个全匹配的过程,在点渲染的操作中,保证每一个模板点,目标图像中都有一个特征点与其对应,实现模板点的全匹配,如图 4 所示,红色点为模板点,点渲染完成后,每一个模板点,在目标图像中都有一个特征距离最近的特征点与其对应。

### 2) 关键点位置信息的增强

在 superglue 特征匹配网络中,注意力机制 GNN 的策略之一通过在描述符中加入特征点位置,整合更多的上下文线索。利用一个关键点编码器,将特征点位置信息进行升维,形成一个可以与描述符进行相加的一个特征向量,如式(11)所示。

$$X_i^{(0)} = d_i + MLP(p_i) \quad (11)$$

式中:  $d_i$  和  $p_i$  分别为第  $i$  个特征点的描述符和位置信息; MLP 使用 5 个多层感知机(全链接),通道数分别为 3、32、64、128、256。在  $p_i$  中,包含着特征点的位置信息以及该点的置信度,由归一化后的关键点坐标和该点的置信度  $scores_i$  拼接得来,公式如下:

$$p_i = [(x_i, y_i) \parallel scores_i] \quad (12)$$

其中,对于输入尺寸为  $H \times W$  的工件图像,其中一个特征点的坐标为  $(X_i, Y_i)$ ,使用图像尺寸对特征点坐标进行归一化的结果如式(13)所示。

$$x_i = \frac{X_i}{H}, y_i = \frac{Y_i}{W} \quad (13)$$

为了使其更适应工件之间的特征点匹配任务,针对生产中工件的形状基本固定的特点,本文对上述  $p_i$  计算公式做了如下修改。首先,图片在经过关键点检测网络后,通过工件关键点可以实现对工件外观轮廓的描绘,因此本文使用工件尺寸实现对特征点坐标的归一化过程;其次,通过引入超参数  $\lambda_k$  增加关键点位置信息在最终匹配描述符中的比重,如式(14)所示。

$$p'_i = [\lambda_k \cdot (x'_i, y'_i) \parallel scores_i] \quad (14)$$

其中,超参数  $\lambda_k$  用制关键点位置信息在描述符中的权重,可以提升关键点位置信息对最终描述符的影响。对于检测到的所有关键点,其最小外接矩形尺寸为  $H_a \times W_a$ ,最小外接矩形的中心点坐标为  $(X_o, Y_o)$ ,则在该工件中,关键点的坐标归一化结果如式(15)所示。

$$x'_i = \frac{X_i - X_o}{H_a} + \frac{1}{2}, y'_i = \frac{Y_i - Y_o}{W_a} + \frac{1}{2} \quad (15)$$

### 3) 特殊关键点的误匹配矫正

当人类被给定一个模糊的关键点来完成匹配任务时,他们会筛选初步匹配的关键点,通过检查每个关键点的上下文线索,从中找到真实的匹配。因此,在进行尺寸检测的模板点全匹配的过程中,除了概率较高的关键

点位置信息和视觉特征信息外,可以通过整合上下文线索更好的实现匹配任务。

当工件特征相似关键点的位置接近时,因为描述符和空间距离都相近,通过在描述符中增强位置信息也不能有效地区分,可能会出现误匹配的情况。在部分匹配过程中,对于误匹配的筛选,主要的方法有两种。第 1 种是交叉匹配,将被匹配到的点进行反向匹配,如果第 1 次匹配结果是将图像  $A$  中的模板点  $p_i^A$  和图像  $B$  中的关键点  $p_i^B$  相匹配,那么第 2 次匹配就反过来操作,将图像  $B$  中的关键点  $p_i^B$  与图像  $A$  中的模板点集进行匹配,如果匹配结果与第 1 次匹配一致,则认为这是一对正确的匹配,反之,则认为匹配对错误,将其剔除。这种消除误匹配的方法虽然准确率很高,但可能会导致在图像  $A$  中的模板点,在图像  $B$  中没有关键点匹配。第 2 种是比值检测,点的特征匹配是通过找到一对点之间的特征距离最近,则认为这是一对匹配点。比值检测是分别计算模板点在图像  $B$  中距离相近的点以及相距次之的点之间的距离,然后求取两个距离之间的比值判断匹配是否正确<sup>[25]</sup>。当比值非常小时,证明  $B$  图中对应该模板点的两个特征点之间距离差距非常大,则证明这是一对正确的匹配,但比值检测的方法太依赖先验信息对阈值的选择。

上述两种误匹配都不适用于本文模板点的全匹配任务,因此本文在交叉匹配的基础上加入了形状约束。当交叉匹配识别到错误点时,通过检测与误匹配点距离相近的若干个,并利用工件的固有形状作为约束条件,选择其中满足约束的关键点作为正确匹配,以此确保每个模板点都有一个正确的匹配点。如图 5 所示,红色框为工件关键点集的最小外接矩形框。对于工件中特征相似的关键点,可以通过不同的约束条件区分,如式(16)所示。

$$constraint = \begin{cases} \cos\alpha < \cos\beta, \alpha \neq \beta \\ \|OM_1\| < \|OM_2\|, \alpha = \beta \end{cases} \quad (16)$$

利用关键点检测后输出工件的关键点坐标,通过最小外接矩形定位工件的几何中心  $O$  和工件偏转角度  $\theta$ ,对于特征相似的两个目标关键点  $M_1, M_2$ ,如图 5(a)所示,通过限制关键点与工件几何中心点  $O$  之间角度完成关键点的区分,当两点位于同一角度时,如图 5(b)所示,通过点之间的距离区分。

## 2 实验

本文实验过程中使用的深度学习框架为 Pytorch2.0.1+cu117,硬件环境为 12th Gen Intel(R) Core(TM) i9-12900H CPU 和 NVIDIA GeForce RTX 3070 Laptop GPU,实验过程中的超参数和原网络保持一致,使用 ADAM 优化器,具体参数如表 2 所示。




图 5 形状约束条件  
Fig. 5 Shape constraint

表 2 实验参数

Table 2 Experimental parameter

| 参数名                | 具体参数         |
|--------------------|--------------|
| 超参数 $\lambda_d$    | 250          |
| 超参数 $\lambda$      | 0.000 1      |
| 正方向阈值 $m_p$        | 1            |
| 负方向阈值 $m_n$        | 0.2          |
| batchsize          | 32           |
| 初始学习率 $l_r$        | 0.001        |
| 衰减稀疏 $\beta$       | (0.9, 0.999) |
| 编码器超参数 $\lambda_k$ | 1.1          |

2.1 关键点检测方法的公开数据集验证

参数量和运行速度对比如表 3 所示,通过本文对原始 Superpoint 网络的改进,网络模型参数量被压缩为原始网络的 7%。对分辨率为 320×320 的图片进行关键点检测,每秒钟处理图像帧数增加 8 张,计算速度提升为原来的 125%。

表 3 参数量和运行速度对比

Table 3 Parameter number and running speed comparison

| 网络模型       | 参数量           | 运行速度/FPS  |
|------------|---------------|-----------|
| Superpoint | 629 568       | 32        |
| 本文         | <b>42 314</b> | <b>40</b> |

为了评估修改后的特征点检测器性能,将本文特征点检测算法的实验结果和传统方法 Harris 和 FAST 进行对比, Harris 和 FAST 均采用 OpenCV 实现,分别在 Hpatches 公开数据集上进行重复性测试。可重复率是指,在同一个场景下变换视角或者光照拍摄的两张照片,同时检测到的特征点与总特征点数量的比值。Hpatches 数据集分为光照变换场景和视角变换场景两个部分,分别在两组变化下进行评估结果如表 4 所示。表 4 可以表明,通过在原 Superpoint 网络中引入深度可分离卷积,优化网络结构,压缩网络层数,引入高效通道注意力机制,使得网络整体运行速度得到提升的同时,几乎不损失检测精度,甚至光照变换场景下表现更优。

表 4 特征点检测器性能评估

Table 4 Characteristic point detector performance evaluation

| 方法         | 可重复率/%      |             |
|------------|-------------|-------------|
|            | 光照变换场景      | 视角变换场景      |
| Harris     | 0.53        | 0.46        |
| FAST       | <b>0.47</b> | 0.4         |
| Superpoint | 0.66        | <b>0.67</b> |
| 本文         | <b>0.67</b> | 0.66        |

2.2 尺寸检测的实例验证

1) 量块尺寸检测实验

为了验证算法的可行性,对 25 mm 的零级量块(精度优于 0.14  $\mu\text{m}$ )进行了尺寸检测实验分析。首先利用关键点检测算法设计量块的关键点,因为实际的量块存在边倒圆的现象(在设计制造过程中,将量块的棱角加工成圆弧形,减少尖锐边缘),因此提取的量块关键点为边倒圆的顶点以及每条边上的一个点,通过边上的点坐标计算量块的标称尺寸。在进行实际的尺寸检测时,量块通过关键点检测模型后,得到的结果如图 6(a)所示,通过点渲染层后,提取到的关键点如图 6(b)所示。




图 6 25 mm 零级量块尺寸检测过程

Fig. 6 Measurement process of 25 mm grade 0 gauge block

量块标称尺寸测量过程如图 7 所示,提取到能够代表量块尺寸的特征点,即尺寸测量点后,通过所有关键点的最小外接矩形计算量块的偏转方向,将尺寸测量点投影到该偏转方向上,利用投影点之间的距离实现量块尺寸的测量,系统尺寸检测结果如表 5 所示。对 25 mm 的零级量块(精度优于 0.14  $\mu\text{m}$ )的标称尺寸进行检测时,系统测量结果的最大偏差为  $\pm 0.02 \text{ mm}$ ,标准差为 0.01 mm,表明系统具有较好的重复性。

2) 标定板尺寸检测实验

在使用传统视觉方法对标定版的棋盘格尺寸进行检测时,往往使用固定的角点提取步骤,使用 Opencv 中的 findChessboardCorners 算子,该方法只针对棋盘格角点提取,但其只能获取到棋盘格的角点坐标,这些角点并没有






图 7 量块尺寸检测示意图  
Fig. 7 Schematic diagram of gauge  
block dimensional measurement

对应的属性,因此不能通过点的直接选取实现尺寸的测量。而本文基于形状匹配的工件全尺寸在线检测方法,在对棋盘格进行尺寸检测时,可以通过对模板点的命名,直接实现所需关键点的选择,进而通过关键点之间的距离实现棋盘格尺寸的检测。首先通过关键点检测算法设计标定板的关键点模板,本文将棋盘格的角点设为标定板的模板点。在进行实际的尺寸检测时,待检测的目标棋盘格通过关键点检测模型后,得到的结果如图 8(a)所示,将其和模板点一起输入到点渲染层后,提取到的关键点如图 8(b)所示。

表 5 25 mm 零级量块尺寸检测实验结果  
Table 5 Experimental results of 25 mm grade 0 gauge  
block dimensional measurement

| 测量次数 | 测量值/mm | 误差/mm |
|------|--------|-------|
| 1    | 25.00  | 0.00  |
| 2    | 25.02  | 0.02  |
| 3    | 25.01  | 0.01  |
| 4    | 25.00  | 0.00  |
| 5    | 25.00  | 0.00  |
| 6    | 25.00  | 0.00  |
| 7    | 24.99  | -0.01 |
| 8    | 24.98  | -0.02 |
| 9    | 25.02  | 0.02  |
| 10   | 24.99  | -0.01 |
| 平均值  | 25.00  | -     |
| 标准差  | 0.01   | -     |

通过对点渲染后的棋盘格关键点进行处理,1×1 棋盘格的标准尺寸为 3 mm×3 mm,以此标定相机的像元大小,计算得到每个像素点代表的实际距离为 0.02 mm。利用 1×1 方格标定的像元大小,对棋盘格的尺寸检测结果如表 6 所示。从表 6 可以看出,方格尺寸测量的最大误差为±0.03 mm,表明了该尺寸检测方法的可行性,对于 2 248×2 048 的标定板图像,检测一张标定板所有尺寸的平均用时为 0.14 s。

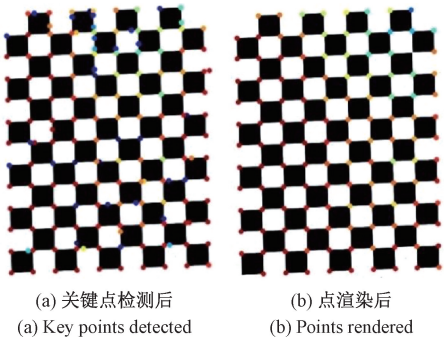



图 8 标定板尺寸检测结果  
Fig. 8 Calibration board size test results

表 6 棋盘格尺寸检测结果  
Table 6 Checkerboard size test results


| 方格大小   | 测量值/mm      | 实际值/mm      |
|--------|-------------|-------------|
| 1×1 方格 | 3.00×3.00   | 3.00×3.00   |
| 2×2 方格 | 5.99×5.99   | 6.00×6.00   |
| 3×3 方格 | 8.99×3.00   | 9.00×9.00   |
| 4×4 方格 | 11.99×11.99 | 12.00×12.00 |
| 5×5 方格 | 14.98×14.98 | 15.00×15.00 |

3) 原电池尺寸检测实验

原电池图像采集系统如图 9 所示,利用双远心系统,通过背光方式成像,利用限位装置保证电池始终处于同一个水平面,并采用接近开关检测电池位置,实现电池图像的采集。利用标准量块对相机的像元大小进行标定,得到相机的像素点与实际尺寸大小比为 0.02 mm/pixel。



(a) 实验装置图  
(a) Experimental installation drawing



(a) 装置示意图  
(b) Installation diagram

图 9 原电池图像采集系统

Fig. 9 Galvanic cell image acquisition system



当使用传统视觉方法对电池尺寸进行检测时,往往利用边缘检测方法得到电池边缘点,通过固定的图像分割比例提取电池的目标区域,进而实现对应尺寸边缘点的选取,利用边缘点之间的距离实现尺寸的检测。而且这种基于固定阈值分割的方法,阈值的获得往往是在电池尺寸参数的基础上,通过多次实验获得的经验参数。当电池的尺寸参数发生变化时,这种基于固定阈值分割比例测量电池尺寸的方法,往往不能正确选取到电池尺寸对应的边缘点。而中国作为全球电池企业的主要供应商,不同国家之间的原电池尺寸参数不同,不同型号电池的尺寸参数也不同,在电池产线长期生产过程中,电池模具的松动与磨损等等,也会导致电池尺寸参数的变化,因此使用固定阈值分割比例实现电池尺寸检测的方法不适用于目前国内企业的生产需求。而本文利用电池形状特征提取的关键点来实现对其形状信息的描述,电池尺寸参数的变化并不影响其抽象的形状信息,并可通过关键点之间的距离,一次性实现电池所有尺寸的计算,具有较强的泛化性和抗干扰能力。

使用本文基于智能形状匹配的零件全尺寸检测方法对原电池进行尺寸检测时,目标电池图像通过轻量化关键点检测模型和点渲染层后,选择到的能够代表电池尺寸信息的关键点如图 10 所示。将关键点投影到电池偏转方向后,通过投影点之间的距离,实现电池的全尺寸测量。



图 10 原电池尺寸检测结果

Fig. 10 Primary cell size test result

静态拍摄下,对同一个七号电池的尺寸进行重复 10 次测量,观察检测的重复性。以电池肩高,拔高外径和负极凸起直径为例,测量结果如表 7 所示。对于分辨率为 2 296×992 的电池图像,选择电池的肩高,拔高外径和负极凸起直径尺寸进行测量分析,由表 7 可得,系统检测重复性精度为 0.03 mm ( $K=3, P=99\%$ ),检测平均耗时约为 0.08 s,表明本文方法能够完成静态测量任务。

而电池产线在正常运转时,其并不能长时间保持同一个速度,因为生产过程中的可能遇到的锌膏甩出,缺少壳体等问题,产线速度在 0~600 个/min 范围内变化。因此会导致接近开关触发相机进行拍摄的时间内,电池位移了不同的距离,在图像中表现出电池位于图像中的不同位置,甚至电池会超出相机的视野范围,进而导致电池位于相机的不同焦平面,相机像素点标定值不准确等问

表 7 同一个七号电池拍摄十次尺寸测量结果  
Table 7 Take ten dimensional measurements  
of the same AAA battery

| 序号  | 肩高/mm | 拔高/mm | 负极凸起直径/mm |
|-----|-------|-------|-----------|
| 1   | 42.09 | 10.09 | 6.34      |
| 2   | 42.09 | 10.09 | 6.34      |
| 3   | 42.09 | 10.09 | 6.35      |
| 4   | 42.09 | 10.09 | 6.34      |
| 5   | 42.11 | 10.11 | 6.35      |
| 6   | 42.09 | 10.09 | 6.34      |
| 7   | 42.09 | 10.09 | 6.34      |
| 8   | 42.09 | 10.09 | 6.35      |
| 9   | 42.11 | 10.09 | 6.34      |
| 10  | 42.09 | 10.09 | 6.34      |
| 平均值 | 42.09 | 10.09 | 6.34      |
| 标准差 | 0.01  | 0.01  | 0.01      |

题。为了解决这个问题,本文在系统中加入了增量型编码器,用于检测产线转速,通过控制延迟拍摄的时间来确保相机触发拍摄时,电池始终处于同一位置。设从接近开关检测到电池,到相机开始拍摄,耗时为  $t_1$ ,期间产线速度不变,电池盘半径  $r=160\text{ mm}$ ,当产线以最大速度运转时,  $W_1=600\text{ 个/min}$ ,不进行延时拍摄;当产线运行速度为  $W_s$  时,设定延时时间为  $\Delta t$ ,若相机两次进行延时触发拍摄时,电池始终处于同一位置,则有:

$$\frac{W_1}{60} \times r \times t_1 = \frac{W_s}{60} \times r \times (t_1 + \Delta t) \tag{17}$$

求解式(17)可得:

$$\Delta t = \frac{W_1 - W_s}{W_s} \times t_1 \tag{18}$$

因此,可设置相机延迟触发拍摄时间为  $\Delta t = \frac{W_1 - W_s}{W_s} t_1$ ,确保相机拍摄时,电池始终处于同一位置。在本实验中,  $t_1=0.03\text{ s}$  时,实验效果最佳,产线以不同速度运转时,电池处在图片中的相同位置。

之后分别在生产速度为 400 和 600 个/min 的七号电池产线上进行实验检测,当产线运行到最大速度时,随机抽取 10 个电池,用螺旋测微计测量 5 次的结果的平均值作为真实值,与系统检测结果进行对比,400 个/min 产线的测量结果如表 8 所示,600 个/分钟产线的测量结果如表 9 所示。由表 8、9 可得,因为电池生产工艺问题,七号原电池的肩高尺寸波动较大,而拔高外径和凸起直径的尺寸波动较小。在七号原电池 400 和 600 个/min 产线上,电池尺寸测量的误差范围均在  $\pm 0.03\text{ mm}$  内,能够满足该企业原电池产线  $\pm 0.05\text{ mm}$  的精度要求。对一个电池所有尺寸的检测时间平均耗时为 0.08 s,能够满足该企业原电池最高生产速度 600 个/min 的要求。

表 8 七号电池系统测量值和真实值对比 (400 个/min)

| Table 8 Comparison between system measurement values and true values for the AAA battery (400 units per minute) |                      |                  |                |
|---|----------------------|------------------|----------------|
| 序号  | 测量值(肩高/拔高外径/凸起直径)/mm | 参考值/mm           | 误差/mm          |
| 1   | 42.09/10.07/6.30     | 42.08/10.09/6.31 | 0.01/0.02/0.01 |
| 2   | 42.05/10.07/6.32     | 42.04/10.07/6.33 | 0.01/0.00/0.01 |
| 3   | 42.09/10.10/6.32     | 42.07/10.09/6.33 | 0.02/0.01/0.01 |
| 4   | 42.14/10.10/6.32     | 42.15/10.09/6.33 | 0.01/0.01/0.01 |
| 5   | 42.14/10.10/6.30     | 42.15/10.09/6.29 | 0.01/0.01/0.01 |
| 6   | 42.16/10.05/6.30     | 42.15/10.07/6.31 | 0.01/0.02/0.01 |
| 7   | 42.12/10.10/6.30     | 42.13/10.09/6.31 | 0.01/0.01/0.01 |
| 8   | 42.09/10.10/6.30     | 42.09/10.09/6.31 | 0.00/0.01/0.01 |
| 9   | 42.09/10.07/6.35     | 42.08/10.07/6.33 | 0.01/0.00/0.02 |
| 10  | 42.12/10.07/6.30     | 42.13/10.09/6.29 | 0.01/0.02/0.01 |

表 9 七号电池系统测量值与真实值对比 (600 个/min)

| Table 9 Comparison between system measurement values and true values for the AAA battery (600 units per minute) |                      |                  |                |
|---|----------------------|------------------|----------------|
| 序号  | 测量值(肩高/拔高外径/凸起直径)/mm | 参考值/mm           | 误差/mm          |
| 1   | 42.07/10.07/6.32     | 42.09/10.07/6.33 | 0.02/0.00/0.01 |
| 2   | 42.09/10.07/6.35     | 42.06/10.09/6.35 | 0.03/0.02/0.00 |
| 3   | 42.09/10.10/6.30     | 42.08/10.07/6.29 | 0.01/0.03/0.01 |
| 4   | 42.14/10.07/6.30     | 42.13/10.09/6.31 | 0.01/0.02/0.01 |
| 5   | 42.16/10.10/6.32     | 42.14/10.11/6.31 | 0.02/0.01/0.01 |
| 6   | 42.12/10.10/6.32     | 42.13/10.09/6.31 | 0.01/0.01/0.01 |
| 7   | 42.12/10.07/6.32     | 42.13/10.09/6.31 | 0.01/0.02/0.01 |
| 8   | 42.16/10.07/6.35     | 42.15/10.09/6.35 | 0.01/0.02/0.00 |
| 9   | 42.09/10.07/6.32     | 42.10/10.07/6.33 | 0.01/0.00/0.01 |
| 10  | 42.09/10.07/6.30     | 42.09/10.07/6.29 | 0.00/0.00/0.01 |

之后,将系统在五号电池 600 个/min 产线上进行尺寸检测实验,尺寸检测数据如表 10 所示,电池尺寸测量的误差范围在±0.03 mm 内,检测平均耗时为 0.09 s,表明本系统不受到电池尺寸参数变化的影响,可以很好的适应不同型号电池的全尺寸检测任务。

表 10 五号电池系统测量值与真实值对比 (600 个/min)

| Table 10 Comparison between system measurement values and true values for the AA battery (600 units per minute) |                      |                  |                |
|---|----------------------|------------------|----------------|
| 序号  | 测量值(肩高/拔高外径/凸起直径)/mm | 参考值/mm           | 误差/mm          |
| 1   | 47.76/13.99/9.12     | 47.75/13.99/9.10 | 0.01/0.00/0.02 |
| 2   | 47.73/13.99/9.10     | 47.72/13.98/9.11 | 0.01/0.01/0.01 |
| 3   | 47.66/13.97/9.12     | 47.68/13.99/9.10 | 0.02/0.02/0.02 |
| 4   | 47.84/13.99/9.11     | 47.82/14.00/9.11 | 0.02/0.01/0.00 |
| 5   | 47.69/14.01/9.12     | 47.67/14.00/9.10 | 0.02/0.01/0.02 |
| 6   | 47.76/13.99/9.10     | 47.79/14.00/9.10 | 0.03/0.01/0.00 |
| 7   | 47.72/13.97/9.10     | 47.70/14.00/9.11 | 0.02/0.03/0.01 |
| 8   | 47.78/13.97/9.08     | 47.79/13.99/9.09 | 0.01/0.02/0.01 |
| 9   | 47.66/14.01/9.10     | 47.69/13.99/9.11 | 0.03/0.02/0.01 |
| 10  | 47.69/13.99/9.12     | 47.70/14.00/9.10 | 0.01/0.01/0.02 |

3 结 论

针对目前尺寸检测算法局限于特定类型的工件,难以适应不同工件的全尺寸检测问题,本文提出了一种基于智能形状匹配的零件全尺寸在线视觉检测方法,通过

在 Superpoint 特征点检测网络中引入深度可分离卷积,压缩网络模型,添加 ECA 注意力机制,实现工件关键点及其描述符的检测,利用关键点实现工件形状的描述。之后利用增强关键点位置信息的 Superglue 特征全匹配算法,得到与工件模板点对应的目标关键点,利用关键点之间的距离实现零件的全尺寸测量。通过量块,标定板

和不同型号原电池的尺寸检测实验证明,通过更改工件的模板点,本文的算法可以很好的适应不同种类工件的全尺寸检测任务,对于量块,标定板和原电池的尺寸测量误差均在 $\pm 0.03\text{ mm}$ 以内,且该方法已经用于实际电池生产过程中的尺寸检测任务。

## 参考文献

- [1] 唐寒冰,巢渊,刘文汇,等.基于机器视觉的大尺寸零件测量方法研究综述[J].电子测量技术,2021,44(17):33-40.  
TANG H B, CHAO Y, LIU W H, et al. Review of measurement methods of large-size parts based on machine vision [J]. Electronic Measurement Technology, 2021, 44(17): 33-40.
- [2] 韩茜茜,耿世勇,路向阳.基于机器视觉的尺寸测量应用综述[J].河南科技,2019,46(5):8-10.  
HAN X X, GENG SH Y, LU X Y. A review of dimension measurement applications based on machine vision [J]. Henan Science and Technology, 2019, 46(5): 8-10.
- [3] 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.  
ZHAO ZH ZH, JIANG M, YIN Z K. Workpiece dimension measurement based on improved Canny operator [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 52-59.
- [4] 李小宝,陆永华,周利华,等.基于机器视觉的电子线束产品尺寸检测方法[J].测试技术学报,2024,38(3):289-297.  
LI X B, LU Y H, ZHOU L H, et al. A dimension detection method for electronic wire harness products based on machine vision [J]. Journal of Test and Measurement Technology, 2024, 38(3): 289-297.
- [5] 李晋鑫,沙玲.基于机器视觉的内丝接头尺寸测量系统设计[J].电子测量技术,2021,44(24):98-104.  
LI J X, SHA L. Design of internal thread joint dimension measurement system based on machine vision [J]. Electronic Measurement Technology, 2021, 44(24): 98-104.
- [6] 张阳婷,黄德启,王东伟,等.基于深度学习的目标检测算法研究与应用综述[J].计算机工程与应用,2023,59(18):1-13.  
ZHANG Y T, HUANG D Q, WANG D W, et al. A review of research and applications of deep learning-based object detection algorithms [J]. Computer Engineering and Applications, 2023, 59(18): 1-13.
- [7] 李帅,安维胜,程卫东,等.基于深度学习的柠檬尺寸自动检测[J].机械设计与制造工程,2024,53(8):86-90.  
LI SH, AN W SH, CHENG W D, et al. Automatic lemon size detection based on deep learning [J]. Machine Design and Manufacturing Engineering, 2024, 53(8): 86-90.
- [8] 戴先鑫,付振山,马栋,等.基于感兴趣区域的螺栓姿态及尺寸检测研究[J].电子测量技术,2024,47(8):134-140.  
DAI X X, FU ZH SH, MA D, et al. Research on bolt pose and dimension detection based on region of interest [J]. Electronic Measurement Technology, 2024, 47(8): 134-140.
- [9] 孙小龙.基于深度学习的贝类海产品尺寸检测系统设计[D].无锡:江南大学,2022.  
SUN X L. Design of shellfish size detection system based on deep learning [D]. Wuxi: Jiangnan University, 2022.
- [10] 许斌,徐凡颖,辛若铭.基于区域灰度梯度差异的摆片基片特征尺寸视觉测量方法[J].仪器仪表学报,2022,43(5):128-135.  
XU B, XU F Y, XIN R M. Visual measurement method for feature size of pendulum substrate based on regional gray gradient difference [J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 128-135.
- [11] 高睿喆.基于视觉的机动车外廓尺寸检测系统研究[D].西安:西安工业大学,2024.  
GAO R Z. Research on vehicle outline dimension detection system based on vision [D]. Xi'an: Xi'an Technological University, 2024.
- [12] 江涛,李媛,贺晨龙.基于轮廓角点检测的螺纹关键参数视觉测量方法[J].电子测量与仪器学报,2022,36(7):54-61.  
JIANG T, LI Y, HE CH L. Visual measurement method for key parameters of thread based on contour corner detection [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7): 54-61.
- [13] 于瀚文,吴一全.基于机器视觉的锂电池缺陷检测研究进展[J].仪器仪表学报,2024,45(9):1-23.  
YU H W, WU Y Q. Research progress on lithium battery defect detection based on machine vision [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 1-23.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv preprint arXiv:1409.1556, 2014.
- [15] DETONE D, MALISIEWICZ T, RABINOVICH A. Superpoint: Self-supervised interest point detection and description [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2018: 224-236.
- [16] LAURENT S. Rigid-motion scattering for image



- classification[D]. Palaiseau: École Polytechnique, 2014.
- [17] LEI B J, KIROS J R, HINTON G E. Layer normalization[J]. ArXiv preprint arXiv: 1607.06450, 2016.
- [18] 宫倩, 别必龙, 范新南, 等. 基于关键点检测的指针仪表读数算法[J]. 电子测量与仪器学报, 2023, 37(3): 66-73.
- GONG Q, BIE B L, FAN X N, et al. Pointer meter reading algorithm based on key point detection [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 66-73.
- [19] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [20] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [21] HUANG Q, GUO X, WANG Y, et al. A survey of feature matching methods [J]. IET Image Processing, 2024, 18(6): 1385-1410.
- [22] 陈佳炫. 基于深度学习的自适应特征匹配模型研究[D]. 昆明: 云南师范大学, 2022.
- CHEN J X. Research on adaptive feature matching model based on deep learning[D]. Kunming: Yunnan Normal University, 2022.
- [23] SARLIN P E, DETONE D, MALISIEWICZ T, et al. Superglue: Learning feature matching with graph neural networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 4938-4947.
- [24] CUTURI M. Sinkhorn distances: Lightspeed computation of optimal transport [C]. Conference and Workshop on Neural Information Processing Systems, 2013.
- [25] 王茂琴. 基于图像匹配的无人机定位技术[D]. 西安:

西北大学, 2022.

WANG M Q. UAV positioning technology based on image matching[D]. Xi'an: Northwest University, 2022.

## 作者简介



**许桢英**, 1999 年于合肥工业大学获得学士学位, 2004 年于合肥工业大学获得博士学位, 现为江苏大学教授、博士生导师, 主要研究方向为声、光无损检测理论与技术。

E-mail: xuzhenying@ujs.edu.cn


**Xu Zhenying** received her B. Sc. degree from Hefei University of Technology in 1999, Ph. D. degree from Hefei University of Technology in 2004. Now she is a professor and Ph. D. supervisor in Jiangsu University. Her main research interests include the theory and technology of acoustic and optical nondestructive testing.



**杨为涛**, 2022 年于江苏大学获得学士学位, 现为江苏大学在读研究生, 主要研究方向为图像处理、机器视觉。

E-mail: 2896387162@qq.com

**Yang Weitao** received his B. Sc. degree from Jiangsu University in 2021. Now he is a M. Sc. candidate of Jiangsu University. His main research interests include image processing and machine vision.



**雷英俊** (通信作者), 2016 年于合肥工业大学获得学士学位, 2019 年于合肥工业大学获得硕士学位, 2023 年于合肥工业大学获得博士学位, 现为江苏大学讲师, 主要研究方向为精密仪器与检测技术。

E-mail: leiyj01@ujs.edu.cn

**Lei Yingjun** (Corresponding author) received his B. Sc. degree from Hefei University of Technology in 2016, M. Sc. degree from Hefei University of Technology in 2019, and Ph. D. degree from Hefei University of Technology in 2023. Now he is a lecturer in Jiangsu University. His main research interests include precision instrumentation and measurement technology.