

DOI: 10.19650/j.cnki.cjsi.J2210752

# 基于关键点检测的航空发动机螺栓安装缺陷自动化检测方法

辛佳雯, 王睿, 谢艳霞, 孙军华

(北京航空航天大学仪器科学与光电工程学院精密光机电一体化教育部重点实验室 北京 100191)

**摘要:**针对航空发动机螺栓存在背景复杂、目标小、且精细特征不明显的问题,本文研究了一种基于关键点检测的航空发动机螺栓安装缺陷的自动化检测方法。首先设计了基于 Faster RCNN 和改进 CPN(AD-CPN)的级联卷积神经网络,实现了图像中螺栓及二维关键点的检测,可判断该螺栓是否脱落、漏装。为进一步检测螺栓的三维安装缺陷,通过欧氏距离选择策略对已检测出的关键点进行双目匹配、筛选以获得检测点对,最后对检测点对三维重构,并计算出螺栓的实际长度,从而判断螺栓是否错装。实验结果表明,相较于 CPN,AD-CPN 的  $mAP$ 、 $AP_{50}$ 、 $AP_{75}$  分别提升了 2.9%、3.3%、4%;螺栓测量长度的相对平均误差约为 3.0%,可见该方法具有较高的缺陷检测准确率,有效保障了航空发动机的安全运行。

**关键词:** 缺陷检测;关键点检测;深度学习;双目立体视觉

**中图分类号:** TH862 TP391.4 **文献标识码:** A **国家标准学科分类代码:** 460.40

## An automatic detection method of aero-engine bolt installation defects based on key points detection

Xin Jiawen, Wang Rui, Xie Yanxia, Sun Junhua

(Laboratory of Precision Opto-mechatronics Technology, Ministry of Education, Institute of Instrumentation Science and Opto-Electronics Engineering, Beihang University, Beijing 100191, China)

**Abstract:** In view of the problems of complex background, small target and inconspicuous fine features of aero-engine bolts, an automated detection algorithm of aero-engine bolt installation detection based on key points detection is proposed. First, a cascaded convolutional neural network based on the Faster RCNN and the improved CPN (AD-CPN) is proposed to achieve the detection of bolts and 2D key points which can determine whether the bolt has fallen off or missed. To further detect the 3D installation detection of the bolt, the Euclidean distance selection strategy is introduced to match and screen the key points to obtain the detected point pairs. Finally, the 3D coordinates of the key points are calculated by using binocular stereo vision technology. In this way, it can judge whether the bolt is wrongly installed. Compared with CPN, the  $mAP$ ,  $AP_{50}$ , and  $AP_{75}$  of AD-CPN are improved by 2.9%, 3.3%, and 4%, respectively. In addition, the relative average error of bolt measurement length is approximately 3.0%. It can be seen that the algorithm could enhance the accuracy of detection, and ensure the safe operation of aero-engines, which has great practical significance.

**Keywords:** defect detection; key points detection; deep learning; binocular stereo vision

## 0 引 言

目前我国的航空发动机制造业在进行紧固件装配检测时,仍采用人工目视结合设备辅助检测的方式<sup>[1]</sup>。此方法具有灵活性高、机动性强的优点,但由于航空发动机结构复杂、零件规格多,在检测时会因人体生理疲劳而造成分拣错误和故障误判,且效率低下。

随着计算机视觉的发展,基于图像的缺陷检测方法<sup>[2]</sup>成为非接触式无损检测技术中的研究热点,有关螺栓的缺陷检测方法也被相继提出。用于行人检测的 Viola-Jones 框架被 Ramana 等<sup>[3]</sup>成功迁移运用在了螺栓松动检测中。深度学习技术也与时俱进应用于螺栓损坏检测, Gibbons 等<sup>[4]</sup>提出了基于卷积神经网络螺栓损坏检测算法,将分类部分更改为背景、正常螺栓与损坏螺栓 3 个类别,大大提高了检测精度。戚银城等<sup>[5]</sup>针对输电线路螺栓类别差异

小、特征提取难的问题,提出了一种双注意力机制方法,增强了不同尺度、不同位置的视觉特征,从而降低了漏判、误判率。张姝等<sup>[6]</sup>则首先利用单步多框目标检测(single shot multibox detector, SSD)切割出存在缺陷的螺栓的连接部位,再通过你只需看一次(you only look once, YOLO)算法检测缺陷螺栓,并增大螺栓在输电线路图像中的占比提高了输电线路图像中螺栓缺陷检测精度。但是目前已报道的都只是基于螺栓图像的二维缺陷检测,因不能计算螺栓实际长度,难以判断螺栓是否错装。

判断螺栓是否错装,可通过三维重建对螺栓进行三维缺陷检测,而基于图像的三维重建依赖于关键点的检测。尺度不变特征转换(scale invariant feature transform, SIFT)<sup>[7]</sup>、加速稳健特征(speeded-up robust features, SURF)<sup>[8]</sup>、快速特征点提取和描述(oriented FAST and rotated BRIEF, ORB)<sup>[9]</sup>等传统特征检测算法在金字塔模型不同层上检测关键点,并将提取的关键点旋转到确定的特征点的方向上,再计算以主方向为基础的坐标系内的关键点的描述子以实现特征点的检测与匹配。Detone等<sup>[10]</sup>提出了基于兴趣点检测器和描述子的自监督网络模型 SuperPoint,通过搭建全卷积模型对全尺寸图像进行操作,并在一次前向扫描中联合计算像素级兴趣点位置和相关描述子,以提高特征点检测的重复性。以上特征点检测算法检测出的特征点多为角点、边缘点、暗区的亮点等突出点,不适合用于计算螺栓长度的关键点获取,且由于航空发动机螺栓图像中存在大量冗余信息,通过对图像中所有像素点进行遍历来提取特征点,算法效率低下。

针对上述问题,本文提出了基于关键点检测的航空发动机螺栓安装缺陷自动化检测方法。首先通过级联卷积神经网络(faster region-based convolutional neural networks and attention-deformable convolution cascaded pyramid network, FC-Net)获得螺栓上下底面关键点的高精度二维坐标,并依此判断螺栓是否脱落或漏装,即检测螺栓是否存在二维缺陷;再基于欧氏选择策略对获取的关键点进行匹配、筛选得到检测点对;最后基于双目立体视觉技术计算螺栓长度,依此判断螺栓是否错装,从而实现了螺栓二维、三维安装缺陷的自动化高效检测。

## 1 螺栓安装缺陷检测总体框架

本文通过制备航空发动机螺栓数据集、构建了基于级联卷积神经网络的关键点检测模型并设计基于双目立体视觉的螺栓长度测量方法,搭建了螺栓安装缺陷检测总体框架,实现了螺栓漏装、脱落、错装等二维及三维安装缺陷检测。

由于航空发动机图像通常在工装现场采集,图像质量易受打光影响,往往存在局部高反光的问题。针对此

问题,在数据集制备模块通过采集多曝光图像序列,再将融合后的图像作为初始数据集,提升了图像质量。

针对航空发动机图像特征不明显、语义信息难提取的问题,本文提出了改进 CPN 网络(attention deformable convolution-cascaded pyramid network, AD-CPN)。根据有关关键点检测模型的特点,通过在网络中嵌入多注意力机制和可变形卷积,使新模型提取更丰富的语义信息,同时加强了对难检测关键点特征的学习,进而提升了关键点检测精度。

由于螺栓关键点检测模型预测得到的关键点为稀疏点,通过传统双目特征点匹配方法进行匹配代价大,因此本文提出了欧氏距离选择策略。基于此来匹配、筛选关键点,以获得用来计算长度的检测点对。

## 2 基于级联卷积神经网络的关键点检测模型

为获得更为准确的螺栓关键点坐标,本文采用级联卷积神经网络实现螺栓二维关键点检测。其中目标检测网络实现图像中螺栓的检测,获得其边界框坐标,作为后续的关键点检测网络的先验信息。接着使用关键点检测网络预测每个螺栓关键点的二维坐标及类别信息。

### 2.1 螺栓检测网络的选择

在如表 1 所示的具有代表性的目标检测网络中,YOLO<sup>[11]</sup>、SSD<sup>[12]</sup>均属于一阶段目标检测网络,具有结构简单、检测速度快的优点,快速区域卷积神经网络(faster region-based convolutional neural networks, Faster RCNN)<sup>[13]</sup>作为两阶段目标检测网络在检测精度尤其是在小目标检测上具有一定的优势。由于本文的研究对象为如图 1 所示的航空发动机螺栓,属于小目标,且螺栓的检测精度其关键点检测精度影响较大,因此本文选择平均精度值(mean average precision, mAP)最高、且帧率(frames per second, FPS)满足工程要求(2 Hz)的以 ResNet50<sup>[14]</sup>为基础卷积神经网络的 Faster RCNN 网络实现螺栓检测。

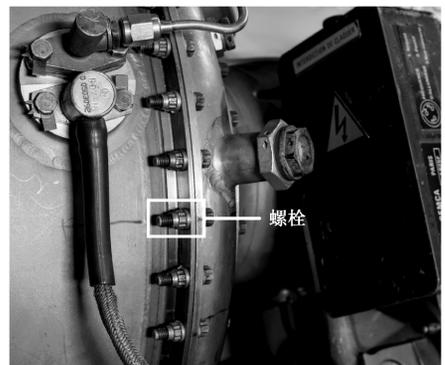


图1 航空发动机螺栓图

Fig. 1 Diagram of the aero-engine bolt

表1 目标检测网络性能对比

Table 1 Object detection network performance comparison

阶段	网络	<i>mAP</i>	<i>FPS/Hz</i>
一阶段	YOLOv1 <sup>[11]</sup>	63.4	45.0
	YOLOv2 <sup>[15]</sup>	69.0	91.0
	SSD300 <sup>[12]</sup>	74.3	46.0
	YOLOv3 <sup>[16]</sup>	74.5	45.5
	Fast RCNN <sup>[17]</sup>	70.0	0.5
两阶段	Faster RCNN VGG-16 <sup>[13]</sup>	73.2	7.0
	Faster RCNN ResNet <sup>[13]</sup>	76.4	5.0

## 2.2 基于改进 CPN 网络的关键点检测

螺栓的二维关键点检测选用级联金字塔 (cascaded pyramid network, CPN) 网络<sup>[18]</sup>。该网络采用两阶段架构,由 GlobalNet 和 RefineNet 组成。其中 GlobalNet 部分利用 ResNet 提取特征,采用 FPN 结构进行特征融合,以同时兼顾分辨率和语义信息。在 RefineNet 中,通过在 GlobalNet 每层输出后设计不同数量的 bottleneck 块,来提取不同层的特征。然后经过不同倍率的上采样后通过拼接的方式来融合各层语义信息,最后再经过一个 bottleneck 输出预测结果。除此之外,RefineNet 部分还采用了 OHEM 技术,即在训练过程中对 loss 进行从大到小排序,最后选择 top-*k* 个 loss 用于网络的反向传播,或者说在一个样本生成的不同的 loss 中选择最大的 loss 样本进行重复训练,使得网络更注重难样本的学习。

为了进一步提升 CPN 网络的性能,本文提出了改进 CPN 网络即 AD-CPN,其主要在以下两个部分对 CPN 网络进行了提升。

### 1) 基于多重注意力机制改进 GlobalNet

在计算机视觉中,注意力机制往往通过衡量权重并对其重新分配来调节网络参数,从而使网络侧重学习图像的关键特征。为此,本文在 GlobalNet 部分引入卷积注意力机制(convolutional block attention module, CBAM)<sup>[19]</sup>和选择性核网络(selective kernel net, SKNet)注意力机制<sup>[20]</sup>,分别从通道、空间和卷积核3个角度生成自适应权重,加强了对关键点特征的提取。改进后的 GlobalNet 如图2所示。

#### (1) CABM 注意力机制

航空发动机图像各通道域中的包含的信息对关键点坐标和类别预测的影响是各不相同的,但网络在提取和处理通道域中的图像特征时采取权重等分的方式。因此,本文在 GlobalNet 部分引入通道注意力机制来解决通道间信息差异性判别的问题。

对于具体的通道,每个像素点都会学习到相应的权重,这些权重则代表该像素空间位置信息的重要程度。

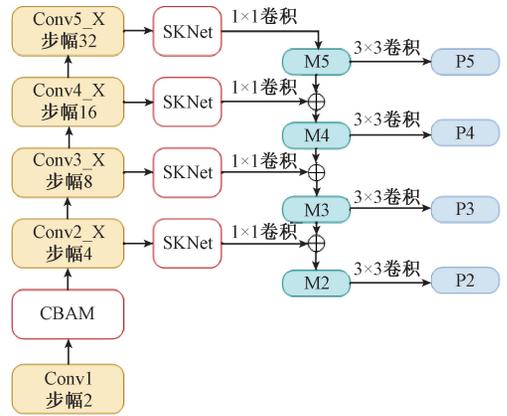


图2 基于多重注意力机制的改进 GlobalNet

Fig. 2 The improved GlobalNet based on multiple attention mechanism

显然,在航空发动机螺栓图像中,不同像素点的重要程度不同,例如位于螺栓底面的像素点比侧面的像素点更为重要。因此,通过引入空间注意力,将注意力矩阵附加在原来的特征图上,增大重要的像素点特征提取,弱化无用像素点特征。

综上,通过在 GlobalNet 部分引入 CBAM 注意力机制,可使网络聚焦更有意义的特征,提升了关键点检测的精度和效率。CBAM 注意力机制结构如图3所示。

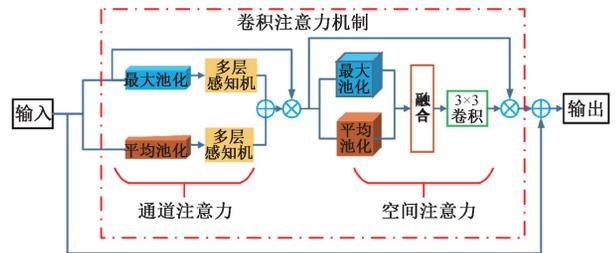


图3 CBAM 注意力机制结构

Fig. 3 The architecture of CABM attention mechanism

在本文方法中,将 GlobalNet 特征提取层 Conv1 输出的特征图作为 CBAM 模块的输入  $F$ ,依次经过通道、空间注意力机制模块。CABM 注意力机制如式(1)、(2)所示,其中  $F$  为 CABM 的输入、 $F_1$  为通道注意力部分的输出、 $F_2$  为空间注意力部分的输出、 $M_c$  为通道注意力权重、 $M_s$  为空间注意力权重。

$$F_1 = M_c(F) \otimes F \quad (1)$$

$$F_2 = M_s(F_1) \otimes F_1 \quad (2)$$

#### (2) SKNet 注意力机制

受视觉皮层神经元可根据受到的刺激来调节感受野大小的启发,Li 等<sup>[20]</sup>提出了 SKNet 注意力机制,通过在神经网络中构建一种动态选择机制,即允许神经元根据

输入自适应地调整其感受野大小,使得不同的输入图像能够得到具有不同重要性的卷积核,加强语义信息的提取,其结构如图 4 所示。

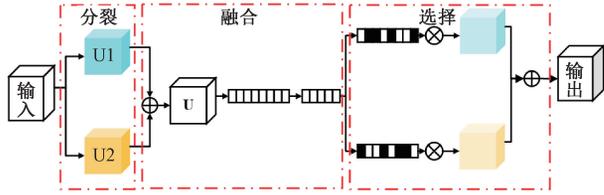


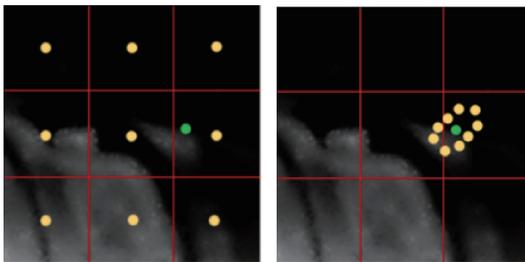
图 4 SKNet 结构

Fig. 4 The architecture of SKNet

螺栓关键点的低层语义特征包含颜色、纹理等特征,可用于区分关键点和背景;高层语义特征为关键点与周围其他像素点的关联性,通过学习高层语义特征可进一步实现关键点检测以及类别预测。由于螺栓关键点的类别预测高度依赖于高层语义特征,因此本文将 SKNet 注意力机制嵌入至 GlobalNet 的 Conv2\_X、Conv3\_X、Conv4\_X、Conv5\_X 层之后,对高层语义特征进一步提取,再将得到的特征图和上一层上采样得到特征图进行融合,从而既实现了语义特征的聚合,也保留了高分辨率。

2) 基于可变形卷积改进 RefineNet

航空发动机螺栓图像中某些关键点的颜色特征、边缘特征不明显,这导致在检测时难度加大,RefineNet 部分主要对这些关键点着重检测。为提高对非显现特征的提取精度,本文在 RefineNet 的每个 bottleneck 块中嵌入可变形卷积<sup>[21]</sup>。与常规卷积相比,可变形卷积通过对特征点添加位置偏移量,使得与卷积核相乘的特征点位置分布不固定,可根据图像内容自适应改变,从而提升了网络对未知变化的适应能力和泛化性能,在提取非显现特征方面具有一定的优势。可变形卷积与标准卷积的采样位置如图 5 所示。



(a) 标准卷积 (a) Standard convolution (b) 可变形卷积 (b) Deformable convolution

图 5 卷积采样位置

Fig. 5 The location map of convolution sampling

可变形卷积运算公式如式(3)所示。

$$Y_{y_0} = \sum_{P_R \in R} w_{P_R} \cdot I_{y_0 + P_R + \Delta P_R} \quad (3)$$

其中,  $I$  表示输入特征图;  $y_0$  表示输出特征图  $Y$  上的每个位置;  $R$  表示卷积核;  $P_R$  表示  $R$  中的所有采样位置的集合;  $\Delta P_R$  表示偏移量。具体操作过程为:首先通过普通卷积操作获得特征图,再将特征图作为输入再次进行卷积操作,此时使每个像素在  $x$ 、 $y$  方向的偏移扩大为原来的两倍,再利用双线性插值算法计算可变形卷积的偏移量。

综上,通过基于 Faster RCNN 和 AD-CPN 的 FC-Net 模型可获得螺栓上下底面关键点的二维坐标,将其与理论安装模块对比可判断是否存在漏装、脱落等二维安装缺陷。

3 基于双目立体视觉的螺栓长度测量

然而,螺栓是否错装却无法通过 FC-Net 模型检测出的螺栓二维关键点来判断,因此需要对二维关键点进行三维重建,通过计算出螺栓的实际长度来实现。双目立体视觉技术与基于激光雷达获取点云数据、基于模型、基于 Kinect 获取深度图像等三维重建技术相比,具有对硬件要求低、成本低、实时性好、需处理数据少、计算复杂度小等优点,所以本文利用双目立体视觉技术实现螺栓关键点的三维重建。

3.1 欧氏距离选择策略

为获得更能还原螺栓三维信息的检测点对,需要对预测得到的螺栓二维关键点进行匹配、筛选。受最近邻算法<sup>[22]</sup>启发,本文提出了欧氏距离选择策略来解决此问题。具体操作如下。

1) 关键点对的匹配

(1) 在右视图中搜索与左视图螺栓关键点相匹配的关键点,即遍历左、右视图的螺栓关键点集合,计算左右视图螺栓中任意两个关键点的欧氏距离,计算公式如式(4)所示。

$$d_{pq} = \sqrt{(x_p - x_{iq})^2 + (y_p - y_{iq})^2}, p, q \in [1, 6] \quad (4)$$

根据左视图螺栓关键点的类别信息不同,即  $p$  值不同,将计算得到的欧氏距离值分为 6 组,记为:  $\{d_{1q}\}, \{d_{2q}\}, \dots, \{d_{6q}\}, q \in [1, 6]$ 。

(2) 计算各组欧氏距离值中的最小值,并将欧氏距离取最小时的  $q$  值记为  $\tilde{q}_p$ 。则欧氏距离取最小时匹配的关键点对记为  $\{x_{lp}, y_{lp}\}, (x_{r\tilde{q}_p}, y_{r\tilde{q}_p})\}, p, q \in [1, 6]$ 。

可依次求得左右视图螺栓所有的关键点对为  $\{(x_{lp}, y_{lp}), (x_{rmp}, y_{rmp})\}$  及对应的最小欧氏距离  $d_{pm_p}$ 。

2) 检测点对的筛选

若要计算螺栓长度,则需要位于同一底面且不共线的 3 点以及另一底面上的 1 点,因此再基于左右视图螺栓中两个关键点欧氏距离值越小,三维重建所得的空间

点坐标更为准确的原理,对匹配得到的6对关键点进行筛选,获得满足上述要求且更能还原螺栓长度信息的4对检测点对。记作:  $\mathbf{m}_{li} = (x_{li}, y_{li}), \mathbf{m}_{ri} = (x_{ri}, y_{ri}), i \in [1, 4]$ 。

### 3.2 螺栓长度计算

#### 1) 检测点对的三维坐标重建

根据双目立体视觉三角测量原理及空间三维点  $\mathbf{M}_i$  与左右视图二维点  $\mathbf{m}_{li}$  和  $\mathbf{m}_{ri}$  的关系,如式(5)、(6)所示,对筛选得到的检测点对进行三维重构获得其三维坐标,记作  $\mathbf{M}_i = \{x_i, y_i, z_i\}, i \in [1, 4]$ ,其中  $\lambda_l$  和  $\lambda_r$  为任意的尺度因子,  $K_l$  和  $K_r$  为双目相机内参,  $(R_l, T_l)$  和  $(R_r, T_r)$  为双目相机外参。

$$\lambda_l \mathbf{m}_{li} = K_l(R_l \setminus T_l) \mathbf{M}_i, i \in [1, 4] \quad (5)$$

$$\lambda_r \mathbf{m}_{ri} = K_r(R_r \setminus T_r) \mathbf{M}_i, i \in [1, 4] \quad (6)$$

#### 2) 长度计算

根据空间中不共线的3点可以确定一个平面的原理,利用最小二乘法拟合  $\mathbf{M}_1, \mathbf{M}_2, \mathbf{M}_3$  所在平面方程为  $Ax + By + Cz + D = 0 (C \neq 0)$ ,其中  $A, B, C$  为平面方程的系数。再求得  $\mathbf{M}_4$  到平面的距离,便可得到螺栓长度,计算公式如式(7)所示。

$$l = \frac{Ax_4 + By_4 + Cz_4}{\sqrt{A^2 + B^2 + C^2}} \quad (7)$$

## 4 实验与结果分析

### 4.1 数据集的制备

#### 1) 双目立体视觉传感器的标定

本文需实现基于双目立体视觉技术的三维缺陷检测,因此实验图像采用双目图像。首先利用两个工业相机搭建双目立体传感器,并对其进行双目标定,可获得两个相机的内参矩阵  $K_1, K_2$ ,如式(8)、(9)所示,以及旋转矩阵  $R$ 、平移矩阵  $T$ ,如式(10)、(11)所示。

$$K_1 = \begin{bmatrix} 5168.100 & 0 & 1227.800 & 0 \\ 0 & 5168 & 1024.300 & 0 \\ 0 & 0 & 1.000 & 0 \end{bmatrix} \quad (8)$$

$$K_2 = \begin{bmatrix} 5129.400 & 0 & 1231.600 & 0 \\ 0 & 5129.300 & 1016.800 & 0 \\ 0 & 0 & 1.000 & 0 \end{bmatrix} \quad (9)$$

$$R = \begin{bmatrix} 0.647 & 2 & -0.085 & 5 & 0.757 & 5 \\ 0.028 & 2 & 0.995 & 7 & 0.088 & 2 \\ -0.761 & 8 & -0.035 & 7 & 0.646 & 9 \end{bmatrix} \quad (10)$$

$$T = \begin{bmatrix} -260.557 & 0 \\ -28.271 & 3 \\ 88.017 & 8 \end{bmatrix} \quad (11)$$

#### 2) 采集多曝光图像序列

航空发动机图像往往存在局部高反光的问题,使得图像特征不明显,从而对后续实验产生干扰。针对此问题,本文由低到高共设置11组曝光时间,从左右两个视角采集航空发动机中包含螺栓部位的多曝光图像序列,并融合多曝光图像序列,如图6所示,可以看出此方法较好的解决了航空发动机图像存在局部高反光问题。

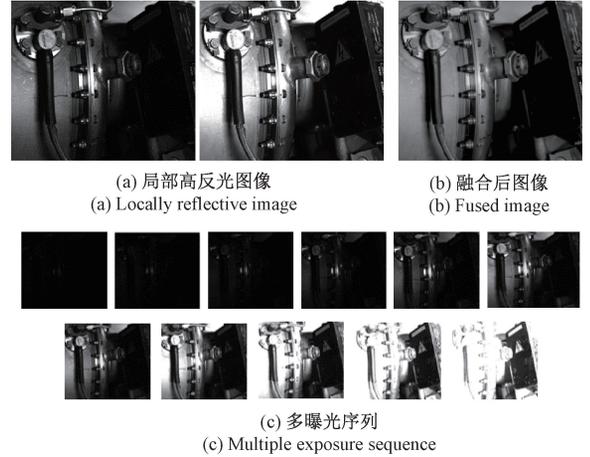


图6 融合多曝光序列效果

Fig. 6 Fusion multi-exposure sequence renderings

利用融合后的多曝光图像构建数据集 BHKP1.0,该数据集包含232张图像,左右视图各116张。

为增加数据集的多样性,对 BHKP1.0 数据集进行随机剪裁、旋转、缩放等数据增强操作,共获得280张图像。再将经数据增强后的数据集,按照6:2:2的比例划分为训练集、验证集和测试集,并对训练集和验证集的图像进行标注,依此构建数据集 BHKP2.0。

### 4.2 评价指标

1) 螺栓检测部分:采用  $mAP$  作为评价指标。

2) 关键点检测部分:使用 MS COCO2017 数据集官方给出的评价指标:关键点相似度(object keypoint similarity, OKS),如式(12)所示。

$$OKS = \frac{\sum_j \exp(-d_j^2/2s^2k_j^2) \delta(v_j > 0)}{\sum_j \delta(v_j > 0)} \quad (12)$$

其中,  $d_j$  表示预测关键点坐标与标签值之间的欧氏距离,  $v_j$  表示该关键点是否可视,  $s$  是检测目标的大小,  $v_j$  为每个关键点的衰减系数。

在实验中基于 OKS,使用  $mAP$ 、阈值为0.5时的平均精度值(average precision IOU = 0.5,  $AP_{50}$ )、阈值为0.75时的平均精度值(average precision IOU = 0.75,  $AP_{75}$ )、平均召回率(average recall, AR)作为评价指标。

3) 长度测量部分:采用相对误差作为评价指标。

### 4.3 关键点检测模型的训练与验证

本文实验均使用 Ubuntu 18.04.6-64 位操作系统,型号为 GeForce RTX 3090 的 GPU,均以 PyTorch 为深度学习框架,Python 为开发语言。

在实验中,优化算法采用随机梯度下降优化算法,权重衰减设置为 0.0005,动量值设置为 0.9。在训练初始阶段,采用学习率“热身策略”,即前 300 次迭代时学习率由 0 线性增长至 0.005,再在第 50、75 轮将学习率下调为上一阶段的 1/10。

#### 1) 螺栓检测网络的训练与验证

为进一步验证螺栓检测网络选择的正确性,在自制数据集 BHKP2.0 上分别训练 SSD300、Faster RCNN (VGG16)、YOLOv3、Faster RCNN (ResNet),并进行验证,实验结果如表 2 所示。可以看出,以 ResNet50 为基础卷积神经网络的 Faster RCNN 在验证集的  $mAP$  达 99.8%,能准确检测图像中的螺栓。

表 2 螺栓检测网络性能对比

Table 2 Bolt positioning network performance comparison

网络	$mAP$
SSD300	86.3
Faster RCNN (VGG-16)	96.4
YOLOv3	97.6
Fast RCNN (ResNet)	99.8

#### 2) AD-CPN 网络的训练与验证

本文通过融入多重注意力机制和可变形卷积对 CPN 网络模型进行了改进,通过消融实验对两种模块在自制数据集上进行了验证,进一步比较两种模块对网络模型的影响。如表 3 所示,加入两种模块后,平均精度值有了明显的提升。其中,仅融入多重注意力模块 (attention-CPN, A-CPN) 时  $mAP$  提升了 1.4%,仅使用可变形卷积 (deformable convolution-CPN, D-CPN) 时  $mAP$  提升了 0.4%,同时引入二者后,  $mAP$  提升了 2.9%,除此之外,  $AP_{50}$ 、 $AP_{75}$ 、 $AR$  分别提升了 3.3%、4.0%、0.6%。其中一个螺栓二维关键点预测的可视化图如图 7 所示。

表 3 AD-CPN 网络消融实验

Table 3 The ablation experiment of AD-CPN network

网络结构	多重注意力	可变形卷积	$mAP$	$AP_{50}$	$AP_{75}$	$AR$
CPN			78.6	85.1	79.5	86.9
A-CPN	√		80.0	87.5	82.0	87.4
D-CPN		√	79.0	87.5	79.0	86.5
AD-CPN	√	√	<b>81.5</b>	<b>88.4</b>	<b>83.5</b>	<b>87.5</b>

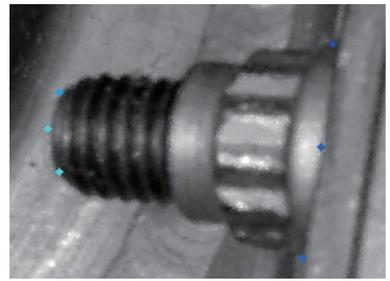


图 7 螺栓关键点预测结果

Fig. 7 Prediction of key points

由实验结果可知,引入注意力机制和可变形卷积后,AD-CPN 网络性能得以提升。因此通过 FC-Net 模型能准确检测出体现螺栓长度关键点的二维坐标。

#### 3) 螺栓的长度计算及缺陷检测实验

通过螺栓检测结果判断该螺栓是否存在漏装、脱落等二维安装缺陷。

进一步的,基于欧氏距离选择策略,对已检测出的二维关键点进行匹配、筛选获得检测点对。图 8 和 9 为本文方法与其他传统及深度学习特征点检测方法的对比图,可知本文方法可以准确检测并匹配、筛选,从而获得能表示螺栓长度的检测点对。再基于双目立体视觉技术重建其三维坐标,进而计算螺栓长度,表 4 为 3 组双目图像中螺栓长度的测量结果,测量相对误差约为 3.0%,证明了该测量方法的有效性。

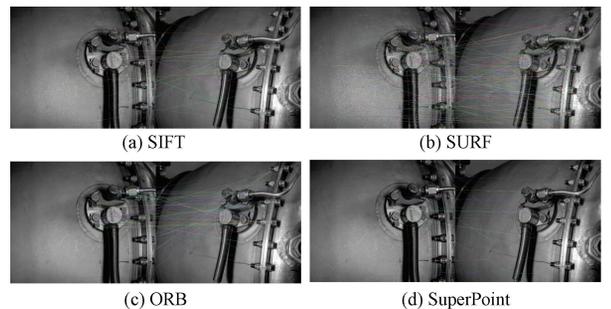


图 8 其他特征点检测方法结果

Fig. 8 The results of other feature points detection methods



图 9 本文检测方法结果

Fig. 9 The results of the proposed detection method

表4 螺栓长度的测量结果表

Table 4 Measurement results of the bolt's length

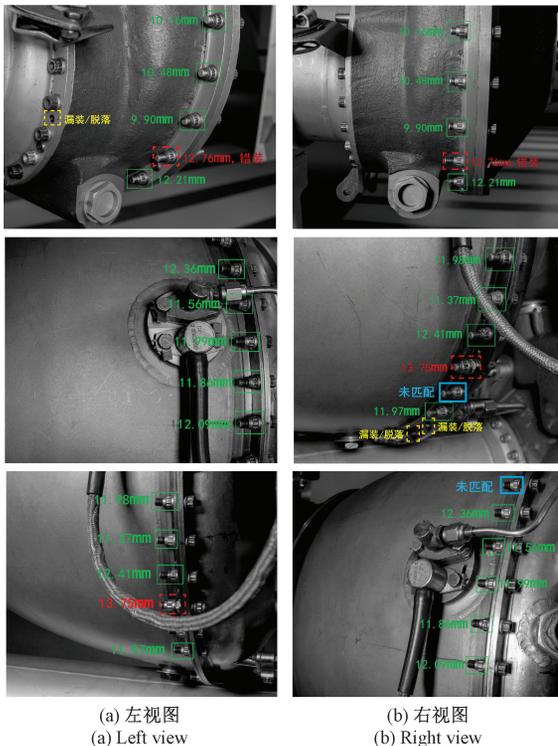
图片	螺栓	是否漏装 /脱落	计算长度 /mm	理论长度 /mm	是否 错装	测量长度 /mm	相对 误差/%	平均相对 误差/%
1	1	是						
	2	否	10.21	10.34	否	10.34	1.27	2.81
	3	否	12.76	10.34	是	12.14	5.10	
	4	否	9.90	10.34	否	10.34	4.44	
	5	否	10.48	10.34	否	10.34	1.53	
	6	否	10.16	10.34	否	10.34	1.74	
2	1	是						
	2	是						
	3	否	11.97	12.14	否	12.14	1.42	
	4	否	13.75	12.14	是	14.56	5.89	
	5	否	12.41	12.14	否	12.14	2.17	
	6	否	11.37	12.14	否	12.14	6.77	
	7	否	11.98	12.14	否	12.14	1.33	
3	1	否	12.09	12.24	否	12.24	1.24	2.68
	2	否	11.86	12.24	否	12.24	3.20	
	3	否	11.99	12.24	否	12.24	2.09	
	4	否	11.56	12.24	否	12.24	5.55	
	5	否	12.36	12.24	否	12.24	0.97	

再将计算所得的螺栓长度与实际长度对比,判断是否存在错装缺陷。图10所示为图像中螺栓的安装缺陷

检测可视化结果。虚线框表示存在漏装或脱落,点线框表示错装,实线框表示该螺栓不存在二维、三维缺陷。粗实线框表示该螺栓只存在于1个视图中无法匹配,可通过改变拍摄视角解决此问题。由图可以看出,本文提出的方法可以同时实现螺栓二维、三维安装缺陷的自动化检测。

## 5 结 论

本文结合深度学习与双目立体视觉技术实现了航空发动机螺栓二维、三维安装缺陷的自动化检测,通过融合多曝光图像序列有效解决了航空发动机图像局部多曝光的问题。并设计了基于Faster-R-CNN和改进CPN(AD-CPN)的FC-Net,提高了螺栓二维关键点检测的精度;通过欧氏距离选择策略对双目图像中关键点匹配、筛选,从而实现基于双目立体视觉技术的螺栓长度测量。并在自制的航空发动机螺栓安装缺陷检测数据集下进行了实验,AD-CPN在验证集的 $mAP$ 、 $AP_{50}$ 、 $AP_{75}$ 为81.5%、88.4%、83.5%,较原模型分别提升了2.9%、3.3%、4%。螺栓长度测量的平均误差约为3.0%。且该方法已投入实际应用,有效实现了航空发动机螺栓安装缺陷的自动检测。



(a) 左视图  
(a) Left view

(b) 右视图  
(b) Right view

图10 螺栓缺陷检测结果

Fig. 10 Results of bolt defect detection

## 参考文献

- [1] 刘秀娟, 胡铁玉, 任燕. 内视镜检测技术在飞机发动机维修上的应用[J]. 工程与试验, 2009(1):34-36.  
LIU X J, HU T Y, REN Y. Application of RVI on maintain of aero-plane engine[J]. Engineering & Test, 2009(1):34-36.
- [2] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022(1):43:198-219.  
ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022(1):43:198-219.
- [3] RAMANA L, CHOI W, CHA Y J. Fully automated vision-based loosened bolt detection using the viola-jones algorithm [J]. Structural Health Monitoring, 2019, 18(2):422-434.
- [4] GIBBONS T J, PIERCE G, WORDEN K, et al. Convolutional neural networks for the detection of damaged fasteners in engineering structures [A]. 9th European Workshop on Structural Health Monitoring[C]. 2018:18-32.
- [5] 戚银城, 武学良, 赵振兵, 等. 嵌入双注意力机制的 Faster R-CNN 航拍输电线路螺栓缺陷检测[J]. 中国图象图形学报, 2021,26(11):2594-2604.  
QI Y CH, WU X L, ZHAO ZH B, et al. Bolt defect detection for aerial transmission lines using Faster R-CNN with an embedded dual attention mechanism[J]. Journal of Image and Graphics, 2021,26(11):2594-2604.
- [6] 张姝, 王昊天, 董骁翀, 等. 基于深度学习的输电线路螺栓检测技术[J]. 电网技术, 2021, 45(7):2821-2829.  
ZHANG SH, WANG H T, DONG X CH, et al. Study on classification and detection of bolt defects in transmission lines based on deep learning [J], Application of IC, 2021,45(7):2821-2829.
- [7] LOWE D G. Object recognition from local scale-invariant features[C]. Proc of IEEE International Conference on Computer Vision, 1999, 2: 1150-1157.
- [8] BAY H, ESS A, TUYTELAARS T, et al. Speeded-up robust features (SURF)[J]. Computer Vision & Image Understanding, 2008, 110(3):346-359.
- [9] RUBLEE E, RABAU D V, KONOLIGE K, et al. ORB: An efficient alternative to SIFT or SURF [C]. 2011 International Conference on Computer Vision, IEEE, 2011: 2564-2571.
- [10] 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.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector [C]. European Conference on Computer Vision, 2016: 21-37.
- [13] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137-1149.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016.
- [15] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision & Pattern Recognition, IEEE, 2017:6517-6525.
- [16] REDMON J, FARHADI A. Yolov3: An incremental improvement [J]. ArXiv Preprint, 2018, ArXiv: 1804.02767.
- [17] GIRSHICK R. Fast R-Cnn[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [18] CHEN Y, WANG Z, PENG Y, et al. Cascaded pyramid network for multi-person pose estimation [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2018.
- [19] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.
- [20] LI X, WANG W, HU X, et al. Selective kernel

networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019; 510-519.

- [21] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017; 764-773.
- [22] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2):91-110.

### 作者简介



**辛佳雯**, 2021 年于吉林大学获得学士学位, 现为北京航空航天大学硕士研究生, 研究方向为图像处理、深度学习。

E-mail: xinjw117@buaa.edu.cn

**Xin Jiawen** received her B. Sc. degree from

Jilin University in 2021. She is currently a master student at Beihang University. Her main research interests include image processing, and deep learning.



**王睿**(通信作者), 1987 年于清华大学获得学士学位, 1990 年于清华大学获得硕士学位, 2006 年于北京航空航天大学获得博士学位, 现为北京航空航天大学副教授, 主要研究方向为信号测试与处理、图像处理、机器学习。

E-mail: wangr@buaa.edu.cn

**Wang Rui** (Corresponding author) received her B. Sc. degree from Tsinghua University in 1987, received her M. Sc. degree from Tsinghua University in 1990, and received her Ph. D. degree from Beihang University in 2006. She is currently an associate professor at Beihang University. Her main research interests include signal testing and processing, image processing, and machine learning.