

基于机器视觉的轴承全表面缺陷在线检测方法^{*}蔡炳彬¹ 黄丹平¹ 张浩田¹ 廖世鹏²

(1.四川轻化工大学机械工程学院 宜宾 644000;2.中国科学院成都计算机应用研究所 成都 610041)

摘 要:为解决当前轴承缺陷图像采集难、检测慢等问题,搭建一种基于机器视觉的单工位轴承全表面缺陷在线检测系统。系统利用线扫描相机结合光学系统进行高效采集轴承全表面图像。所搭建的缺陷检测网络模型以 ConvNext 为特征提取网络,利用特征融合补充特征信息;再进行轻量化改进;同时采用多任务学习的训练方法,使模型具有针对性处理各层次特征信息的能力,最终显著提升模型在轴承表面缺陷检测任务上的表现。实验表明,相比 ConvNeXt-Tiny 来说,所搭建深度学习模型的检测精度模型提高了 4.14%,检测精度达 99.02%。单工位轴承全表面缺陷在线检测系统依靠 CPU 进行计算时,平均检测时间为每个轴承 0.735 s。系统体积小、成本低,同时满足轴承表面缺陷在线检测的要求,具有良好的应用前景。

关键词: 轴承;缺陷检测;多任务学习;轻量化;特征融合;深度学习

中图分类号: TN919.8;TP391 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Online detection method for full surface defects of bearings
based on machine visionCai Bingbin¹ Huang Danping¹ Zhang Haotian¹ Liao Shipeng²

(1. School of Mechanical Engineering, Sichuan University of Science & Engineering, Yibin 644000, China; 2. Chengdu Institute of Computer Application, Chinese Academy of Sciences, Chengdu 610041, China)

Abstract: To address the current challenges of difficult image acquisition and slow detection for bearing defects, a single-station online detection system for full surface defects of bearings based on machine vision has been developed. The system utilizes a line-scan camera in conjunction with an optical system to efficiently capture images of the entire surface of the bearings. The defect detection network model constructed is based on ConvNeXt as the feature extraction backbone, employing feature fusion to supplement feature information, it then undergoes lightweight modifications. Additionally, a multi-task learning training approach is adopted, enabling the model to effectively process feature information at various levels, thereby significantly enhancing its performance in bearing surface defect detection tasks. Experimental results show that compared to ConvNeXt-Tiny, the proposed deep learning model achieves a 4.14% improvement in detection accuracy, reaching 99.02%. When relying on CPU for computation, the average detection time per bearing by the single-station full surface defect online detection system is 0.735 seconds. This system is characterized by its compact size, low cost, and ability to meet the requirements for online detection of bearing surface defects, showcasing promising application prospects.

Keywords: bearing; defect detection; multi-task learning; lightweight; feature fusion; deep learning

0 引 言

轴承是各种机械设备的基础件,轴承缺陷检测对于确保机械设备正常运行、保证生产效率和产品质量至关重要^[1]。轴承外表面在加工成型以及装配搬运过程中,容易

因为磕碰、刮擦、腐蚀等状况产生缺陷。这些存在表面缺陷的轴承安装在设备上可能导致设备运转不稳定、噪音增加、寿命缩短,从而影响流水线的生产效率、产品质量甚至危害人身安全^[2]。因此,及时发现轴承表面缺陷对于确保机械设备正常运行、提高生产效率与质量、降低维护成本至关

收稿日期:2024-12-01

^{*} 基金项目:国家自然科学基金(52370067)、过程装备与控制工程四川省高校重点实验室开放基金(GK202209)、四川省重点实验室资助项目(NJ2018-05)资助

重要。

目前国内外相关科研人员对轴承的自动检测方法已进行了广泛的研究。张炎亮等^[3]利用变分模态分解(variational mode decomposition, VMD)与时频域熵(time-frequency domain entropy, TFDE)特征提取及改进的白蚁群算法优化BP神经网络,提高了滚动轴承故障诊断的准确性和稳定性。廖达海等^[4]通过滤波、剪切波变换、归一化阈值曲面法等算法实现了对陶瓷轴承内圈沟道的缺陷检测。Ma等^[5]通过分层注意力、语义对齐、区域提议网络等机制提出一种视觉层次注意力检测器,可检测不同尺度轴承缺陷。Jiang等^[6]设计自适应伽玛校正与边缘阈值分割耦合算法,用于陶瓷轴承滚子表面缺陷的检测。陈仁祥等^[7]利用子空间域对抗判别网络结合高效通道注意力机制,克服了不同型号滚动轴承特征尺度差异问题。Dong等^[8]设计嵌入摩擦电传感器的滚动轴承,通过信号分解和自动机器学习实现了滚动球缺陷的诊断。杨东毅等^[9]通过线扫描技术实现轴承全表面的采集,利用改进的VGG16(visual geometry group 16-layer network)进行缺陷检测,实时性仍有提升空间。Yu等^[10]提出基于平稳小波变换的多尺度分解增强算法,用于陶瓷轴承球表面缺陷检测。Li等^[11]利用声振信号数据级融合和图神经网络,实现滚动轴承故障准确分类。Shen等^[12]通过深度学习图像缺陷检测与物理知识融合的方法,实现滚动轴承故障检测。袁天乐等^[13]提出区域预提取的预处理算法,同时在YOLOv5(you only look once version 5)添加了改进的多头自注意力机制,从而提高模型缺陷检测性能。钱佳立等^[14]基于激光散射和剪切干涉光学原理,设计精密可调节的球体表面微小缺陷检测平台。Kang等^[15]利用基于蒸馏学习的Vision Transformer模型,实现对航空发动机滚动轴承故障异常的高精度检测。张金汇等^[16]基于改进域对抗网络(subdomain adversarial neural network, SANN),通过Wasserstein距离与局部最大平均偏差(local maximum mean discrepancy, LMMD)解决了复杂工况下轴承故障数据特征分布差异问题,提高了无监督故障识别精度。Li等^[17]利用动量对比双对抗(momentum contrastive dual adversarial, MCDA)方法实现滚动轴承开放集缺陷迁移诊断,通过无监督聚类和域适应提高故障识别的适应性和准确性。

综上所述,轴承表面缺陷检测方法已经取得了一定成果,但大部分检测方法是基于面阵视觉传感器的检测,而基于面阵视觉传感器的采集方式通常依靠多工位、多传感器的应用方式来实现外表面的采集。这种采集方法在硬件上存在运动部件多,可靠性差、设备体积大、轴承表面信息采集不完整等问题。除此之外,在算法上,存在检测速度慢,或依靠GPU(graphics processing unit)进行处理,硬件成本高。

因此,搭建一个易采集、检测快的轴承表面缺陷检测系统具有重要意义。本文针对多工位多传感器采集的问题,

设计单工位采集方法;其次,所采集的图像存在随机畸变,因此需要对畸变进行矫正;最后需要搭建轻量化轴承表面缺陷检测网络进行快速缺陷检测。

1 单工位轴承外表面缺陷检测系统

本文提出的单工位轴承外表面缺陷检测系统主要由成像模块、计算决策模块、运动控制模块、机械结构4个部分组成。整个轴承外表面缺陷检测系统的框架如图1所示。

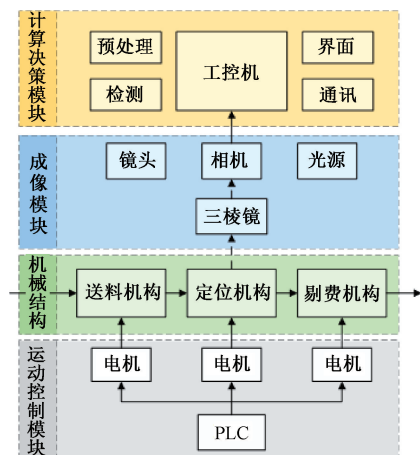


图1 轴承外表面缺陷检测系统框图

Fig. 1 Bearing outer surface defect detection system diagram

依靠机械结构部分的支撑、运动控制部分的节奏控制,轴承通过送料机构逐个送入定位机构,并被定位机构的限位装置限制、传动轮装置的转动,使得轴承转动起来并被相机扫描全部外表面,从而完成表面图像采集。

1.1 成像模块

成像模块是本文所提系统实现单工位采集的关键,其主要由线阵视觉传感器、镜头、光源、三棱镜组成。如图2所示,所用的三棱镜有两个互相垂直的透光平面,三角棱镜斜面为化学镀镍层,与镜子一样具有光线反射效果。

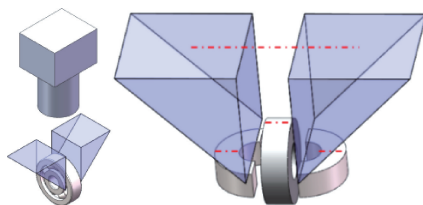


图2 线扫描采集示意图

Fig. 2 Line scan acquisition schematic

本文使用一个线阵视觉传感器,并在一个方向单次曝光即可获得轴承全表面视觉信息的核心部件是两个对称放置的45°三棱镜,其光学成像原理如图3所示,橙色带箭头的线为光的传播方向。

将线阵视觉传感器放置在三棱镜上方,轴承端面的光经45°三棱镜反射后,即可进入线阵视觉传感器。轴承柱面的光可直接入射到线阵视觉传感器中。最后使轴承转动,

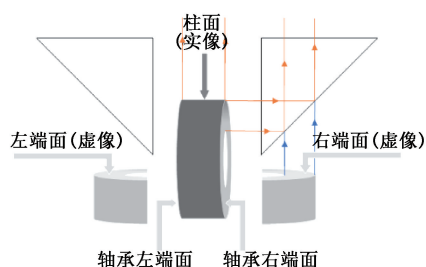


图 3 光学成像原理示意图

Fig. 3 Optical imaging principle schematic

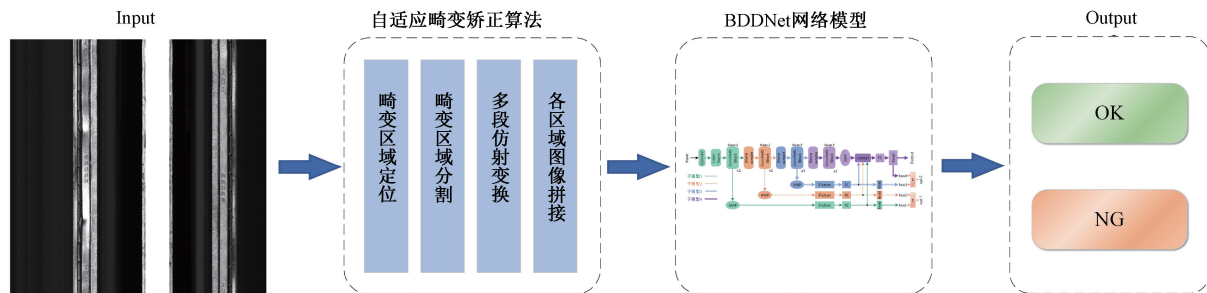


图 4 整体算法框图

Fig. 4 Overall algorithm flowchart

1) 自适应畸变矫正算法

由于成像模块会受到运动控制模块的震动影响,导致轴承相对相机镜头左右移动。采用线阵视觉传感器成像时,轴承柱面和轴承端面所形成的像会出现随机畸变。因此需要将轴承视觉信息进行修复。对此,本文提出自适应畸变矫正算法对所采集的随机畸变轴承图形进行矫正,其原理如图 5 所示。

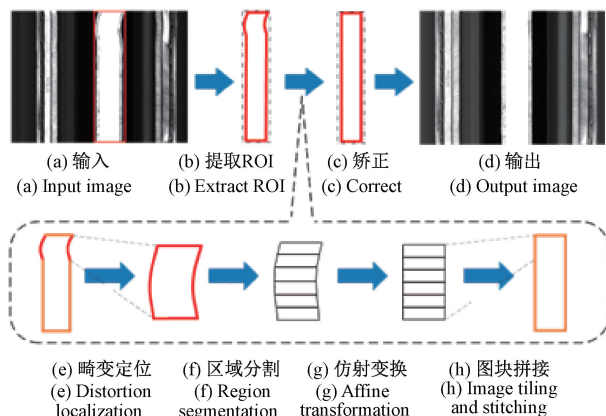


图 5 自适应畸变矫正算法原理示意图

Fig. 5 Schematic illustrating the principle of adaptive distortion correction algorithm

该方法首先利用传统图像处理算法将图像中的轴承 ROI 区域提取出来,然后用自适应畸变位置定位算法找到 ROI 区域中的畸变区域,最后应用多段仿射变换实现畸变的矫正。其数学原理如式(1)所示,可具象化为图 6。

线阵视觉传感器就可完整采集轴承外表面视觉信息。

1.2 计算决策模块

本模块根据所采集图片进行检测,得出轴承是否合格的结果,并发送是否剔费等决策。其中的轴承表面缺陷检测方法如图 4 所示,该方法包含自适应畸变矫正预处理算法和轴承表面缺陷检测网络模型 BDDNet (bearing defect detection network)。所提出的轻量化 BDDNet 网络模型在满足工业在线检测速度的同时,可保证检测精度,为轴承外表面缺陷在线检测任务提供一种高效的解决方案。

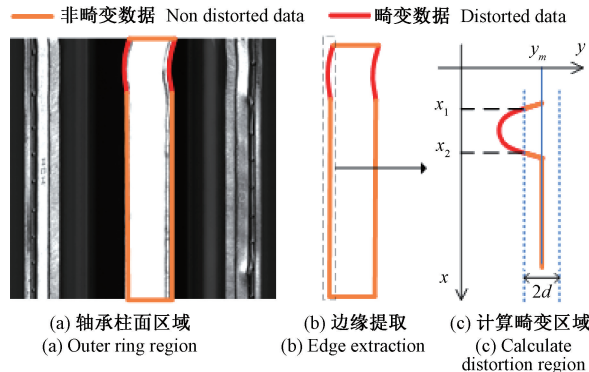


图 6 畸变定位示意图

Fig. 6 Distortion localization schematic

$$Z = \begin{cases} \mathbf{D}_{ROI} = \mathbf{H} \odot \mathbf{Db} \\ \mathbf{Db}_i = \begin{cases} 1, & |y_m - y_i| > d \\ 0, & |y_m - y_i| \leq d \end{cases} \end{cases} \quad i = 1, 2, \dots, h \Rightarrow$$

$$(x_1, x_2) = f(Z)$$

(1)

式中: Z 表示待处理的数据域; \mathbf{D}_{ROI} 表示被标记的缺陷数据区域; \mathbf{H} 是根据图像高度 h 确定的一个递增向量; \mathbf{Db} 是根据图像高度确定并进行计算后得到的布尔向量; \mathbf{Db}_i 表示 y_i 与 y_m 的差是否大于 d 的布尔值; x_1, x_2 表示计算所得的区间。

如图 6 所示,从边缘提取出所有点的坐标数据集(后文简称点集),并将点集出现次数最多的 y 值作为无畸变的理想值,如图 6 (c) 中 $y = y_m$ 的蓝色细实线。点集内的点到理想线 $y = y_m$ 的横向距离大于 d 的,则认为是畸变

点,如图 6 (c)所示,两条蓝色虚线之外的红色实线就被认为是畸变点。这些畸变点对应的 x 坐标区间(如图 6(c)的 X_1 到 X_2 区间)则是畸变位置。

传统的特征检测算法如 Hough 只能对特定的特征进行提取^[18],无法处理本文的随机畸变。因此,本文利用仿射变换将其矫正。

若是用仿射变换一次性矫正畸变图形,将产生较大误差,如图 7 所示。因此,本文依靠线扫描相机成像具有天然水平性的特点,将畸变区域分为多个上下两边为水平的四边形来做多段仿射变换即可解决该问题。本文仅依靠水平剪切的原理来矫正畸变,其数学原理如式(2)所示。

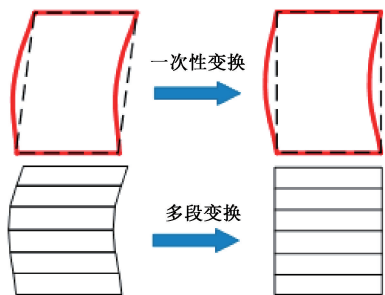


图 7 不同变化方式区别

Fig. 7 Differences in various modification approaches

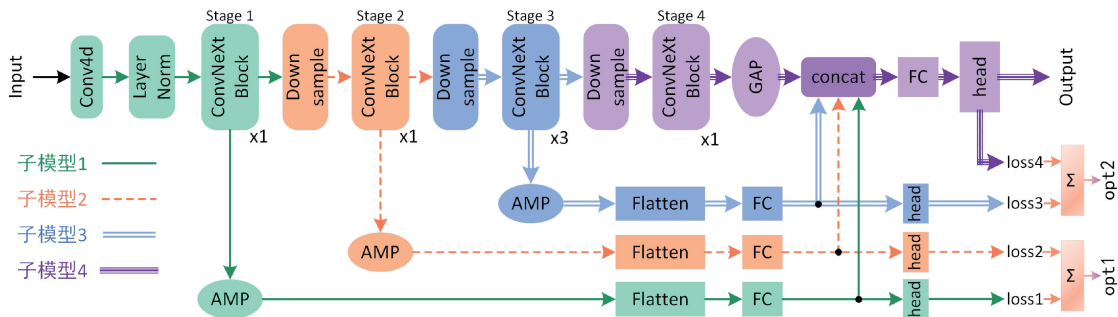


图 8 BDDNet 网络结构

Fig. 8 BDDNet network structure

(1) 特征提取网络及其特征提取分析

BDDNet 将 ConvNeXt 作为特征提取网络。ConvNeXt 是一种结合了多种网络特点的新型 CNN 网络模型,在公共数据集上已经与 Transformer 具有同等甚至更好的性能表现^[19]。在本文数据集中,综合性能表现也是最优,故选择 ConvNeXt 网络作为特征提取网络。

实验发现,在本文检测系统得到的数据集上,ConvNeXt 检测精度未达到工业要求。将特征图可视化发现,输入图像经过多层特征提取后,细节信息几乎消失,如图 9 所示。但轴承存在微小缺陷,这种缺陷需要大量的细节特征给予支持,仅依靠语义信息难以检测。ConvNeXt-Tiny 虽然是最小的 ConvNeXt 模型,但其层数依然较深、参数量相对过大,细节信息变为语义信息而流失,从而影响了轴承微小缺陷的检测,同时难以达到轴承在线检测的

$$\begin{bmatrix} x^* \\ y^* \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & k & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \Leftrightarrow \begin{cases} x^* = x + ky \\ y^* = y \end{cases} \quad (2)$$

式中: x^* 、 y^* 分别表示变换后的 x 、 y 坐标; x 、 y 表示变换前的原始 x 、 y 坐标; k 为错切系数。式(2)表明,只需求出错切系数 k 即可完成水平错切变化。而错切系数与平行四边形的内角有关。因此算法整体计算量不高,具有较快的运算速度。

通过自适应畸变矫正算法修正畸变,解决了轴承外表面图像因随机机械抖动导致的畸变问题,提高图像的几何形状精度,从而为后续的轴承表面缺陷检测网络提供高质量的视觉信息。

2) BDDNet 网络模型

针对所采集并预处理后的轴承全表面图像,构建了 BDDNet (bearing defect detection network) 网络模型。BDDNet 以 ConvNeXt 为特征提取网络,并调整不同阶段的堆叠次数以达成轻量化目的,同时,利用特征融合方法提升网络整体性能,最后,利用多任务学习与子模型组合的新型训练方法增强模型细节特征的提取能力,从而满足轴承表面缺陷检测的精度、速度要求。其网络结构如图 8 所示。

速度要求。

因此,本文通过降低 Block 的堆叠次数,来减少网络层数,达到轻量化的目的,同时减少细节信息的丢失。实验证明,在参数量大幅下降的同时,留存的细节信息使得模型检测精度下降较少,模型检测速度大幅提升。同时,为弥补网络检测精度与进一步利用细节信息,本文提出特征融合与多任务学习两种方法。

(2) 细节信息的弥补

多尺度特征融合的方法可将不同层级的特征进行整合与利用,从而提高整个网络的表征能力。融合方法如图 8 所示。

若直接将各个 stage 输出的特征信息进行融合会导致最终的特征向量过大。为解决该问题,采用自适应最大池化下采样对各个 stage 的特征信息进行提取。其计算公式

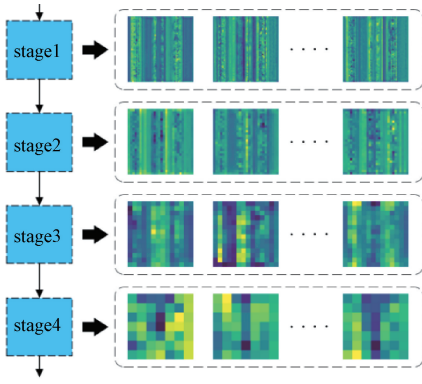


图 9 可视化特征图

Fig. 9 Visualized feature map

如下:

$$\begin{cases} kernel_size = input_size - (output_size - 1) \times stride \\ stride = \lfloor input_size / output_size \rfloor \end{cases} \quad (3)$$

式中: $kernel_size$ 表示池化核大小; $input_size$ 、 $output_size$ 分别表示输入特征的大小和输出特征的大小; $stride$ 表示池化步长。

池化后的特征信息通过全连接层进行映射,最后才进行特征融合。目前常用的特征融合方法为拼接(Concat)、逐元素相加(Add)与逐元素相乘(Multi)。假设被融合的 4 个 stage 特征信息分别为:

$$\mathbf{X}_1 = [X_{1_1}, X_{1_2}, \dots, X_{1_a}] \quad \mathbf{X}_2 = [X_{2_1}, X_{2_2}, \dots, X_{2_b}]$$

$$\mathbf{X}_3 = [X_{3_1}, X_{3_2}, \dots, X_{3_c}] \quad \mathbf{X}_4 = [X_{4_1}, X_{4_2}, \dots, X_{4_d}]$$

则 3 种特征融合的数学公式如式(4)~(6)所示。

$$\begin{cases} \mathbf{X}_{Concat} = \mathbf{X}_1 \cup \mathbf{X}_2 \cup \mathbf{X}_3 \cup \mathbf{X}_4 = \\ \begin{bmatrix} X_{1_1}, \dots, X_{1_a}, X_{2_1}, \dots, X_{2_b}, X_{3_1}, \dots, X_{3_c}, \\ X_{4_1}, \dots, X_{4_d} \end{bmatrix} \\ |\mathbf{X}_{Concat}| = |\mathbf{X}_1| + |\mathbf{X}_2| + |\mathbf{X}_3| + |\mathbf{X}_4| = \\ a + b + c + d = n \end{cases} \quad (4)$$

$$\begin{cases} \mathbf{X}_{Add} = (\mathbf{W}_1 \odot \mathbf{X}_1) \oplus (\mathbf{W}_2 \odot \mathbf{X}_2) \oplus (\mathbf{W}_3 \odot \mathbf{X}_3) \oplus \\ (\mathbf{W}_4 \odot \mathbf{X}_4) = \\ \begin{bmatrix} \mathbf{W}_1 \times \mathbf{X}_1 + \mathbf{W}_2 \times \mathbf{X}_2 + \mathbf{W}_3 \times \mathbf{X}_3 + \mathbf{W}_4 \times \mathbf{X}_4 \\ \vdots \\ \mathbf{W}_a \times \mathbf{X}_{1_a} + \mathbf{W}_b \times \mathbf{X}_{2_b} + \mathbf{W}_c \times \mathbf{X}_{3_c} + \mathbf{W}_d \times \mathbf{X}_{4_d} \end{bmatrix} \\ |\mathbf{X}_{Add}| = |\mathbf{X}_1| = |\mathbf{X}_2| = |\mathbf{X}_3| = |\mathbf{X}_4| = a = \\ b = c = d \end{cases} \quad (5)$$

$$\begin{cases} \mathbf{X}_{Multi} = (\mathbf{W}_1 \odot \mathbf{X}_1) \odot (\mathbf{W}_2 \odot \mathbf{X}_2) \odot (\mathbf{W}_3 \odot \mathbf{X}_3) \odot \\ (\mathbf{W}_4 \odot \mathbf{X}_4) = \mathbf{W} \odot \mathbf{X}_1 \odot \mathbf{X}_2 \odot \mathbf{X}_3 \odot \mathbf{X}_4 = \\ \begin{bmatrix} \mathbf{W}_1 \times \mathbf{X}_{1_1} \times \mathbf{X}_{2_1} \times \mathbf{X}_{3_1} \times \mathbf{X}_{4_1} \\ \vdots \\ \mathbf{W}_a \times \mathbf{X}_{1_a} \times \mathbf{X}_{2_b} \times \mathbf{X}_{3_c} \times \mathbf{X}_{4_d} \end{bmatrix} \\ |\mathbf{X}_{Multi}| = |\mathbf{X}_1| = |\mathbf{X}_2| = |\mathbf{X}_3| = |\mathbf{X}_4| = a = \\ b = c = d \end{cases} \quad (6)$$

式中: \oplus 、 \odot 分别表示逐元素相加、逐元素相乘; \cup 表示拼接; \mathbf{W} 表示权重; a 、 b 、 c 、 d 分别表示 \mathbf{X}_1 、 \mathbf{X}_2 、 \mathbf{X}_3 、 \mathbf{X}_4 的特征向量长度。

综上所述,Concat 将特征维度增加至 n 维,从而增强网络的表达能力,但也增加了模型的参数量。Add 后特征的维度不变,对应元素进行相加以强化或弱化特征,因此会丢失一些信息。Multi 使特征进行非线性组合,会抑制或放大某些特征。鉴于轴承表面缺陷检测需要更多细节信息,本文选择 Concat 方法来融合 4 个 stage 的特征。

(3) 强化细节特征提取的多任务学习

为增强 BDDNet 网络提取图像细粒度特征信息能力,本文提出一种 BDDNet 网络训练及网络参数优化策略。由于细节信息在模型浅层较为丰富,因此,本文将 BDDNet 模型按 stage 划分为 4 个独立的子模型,同时损失函数从 1 个变为 4 个,4 个子模型类似串联在一起,但特征存在依赖关系。如图 8 所示,不同的颜色代表不同的子模型网络。

每个子模型的任务特点都不同。如子模型 1 为最浅层的模型,它的任务是根据 stage1 的细节特征信息检测缺陷轴承;而子模型 3 作为深层的模型,主要任务是根据语义信息得出检测结果。子模型 4 的任务则是根据多尺度特征信息综合判断后得出检测结果。因此可认为, BDDNet 模型分为 4 个任务对模型进行针对性训练,能使模型关注的特征更具针对性,并以此优化参数。该多任务训练方法使 BDDNet 网络从浅层到深层都有各自的最佳参数,从而强化模型处理细节信息的能力。

通过 4 个损失函数计算每个子模型的损失,可对每个阶段的特征进行针对性约束,即可以有效利用细节特征,又可以高度整合语义信息。4 个损失函数如式(7)所示。

$$\begin{cases} loss1 = - \sum_{i=1}^{class} y_{1_i} \log(\widehat{y}_{1_i}) \\ loss2 = - \sum_{i=1}^{class} y_{2_i} \log(\widehat{y}_{2_i}) \\ loss3 = - \sum_{i=1}^{class} y_{3_i} \log(\widehat{y}_{3_i}) \\ loss4 = - \sum_{i=1}^{class} y_{4_i} \log(\widehat{y}_{4_i}) \end{cases} \quad (7)$$

式(7)为 4 个子模型的损失函数,均为交叉熵损失函数; $class$ 表示类别数,其中 y_1 、 y_2 、 y_3 、 y_4 为各子模型对应的真实标签, $\widehat{y}_1 \sim \widehat{y}_4$ 分别为子模型 1 到子模型 4 的预测值。

经试验发现:将子模型 1 与子模型 2 的参数与 loss 分别进行组合后送入优化器 1 进行参数调节;子模型 3 与子模型 4 同样组合后用优化器 2 进行参数调节时, BDDNet 模型精度最高。如图 10 所示。

组合后,优化器将根据两个子模型的总 Loss 求解梯度,然后反向传播优化两个子模型组成的参数组。所以组合模型 1 的优化原理公式如式(8)所示。

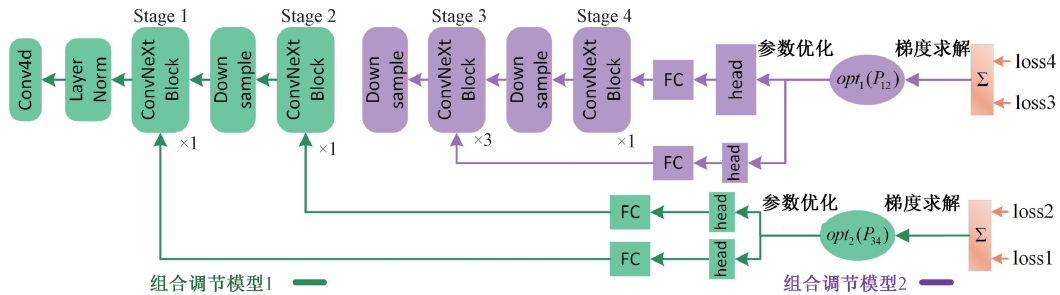


图 10 参数优化示意图

Fig. 10 Parameter optimization schematic

$$\begin{cases} L_1 = loss1 + loss2 \\ P_1 = \{P_{model1}, P_{model2}\} \Rightarrow \\ opt_1(P_1) \rightarrow \min(L_1) \end{cases} \quad (8)$$
$$P_1^{new} = P_1 - lr_1 \times \nabla_{P_1} L_1(P_1)$$

$$\begin{cases} L_2 = loss3 + loss4 \\ P_2 = \{P_{model3}, P_{model4}\} \Rightarrow \\ opt_2(P_2) \rightarrow \min(L_2) \end{cases} \quad (9)$$
$$P_2^{new} = P_2 - lr_2 \times \nabla_{P_2} L_2(P_2)$$

式中: L_1 为子模型 1 与子模型 2 的总损失; P_1 为子模型 1 与子模型 2 的总参数; lr_1 为学习率; $\nabla_{P_1} L_1(P_1)$ 表示损失函数 L_1 在参数 P_1 处的梯度。将总参数 P_1 送入优化器 opt_1 后,即可同时协调子模型 1 与子模型 2 的参数,使它们的组合总损失 L_1 达到最小。同理可得,组合模型 2 的优化原理如式(9)所示。组合后的模型可综合考虑被组合子模型的特征,实现不同层级特征的合作学习。

通过采用多任务学习的新型训练策略,模型能够摆脱对单一特征的依赖,实现既关注细节又关注语义的多重目标;有效增强模型捕获和保留细节特征的能力,同时确保了高层次语义信息的有效利用,从而提高了模型在任务中的检测全面性和准确性。子模型参数与 loss 的组合,使模型能够综合考虑不同层次的特征信息,从而得出组合模型的最优解,而不是子模型的局部最优解,这有助于更好地协调不同子模型的学习过程。

2 实验与分析

2.1 单工位轴承外表面缺陷检测系统及数据集

所搭建的单工位轴承外表面缺陷检测系统如图 11 所示。轴承通过滑槽到入口后,拨轮便将轴承逐个送入红色方框内进行光学系统成像(成像原理如图 3 所示),然后从下方送出。系统配置如表 1 所示。

数据集所用测试轴承一共 2 000 个,全部来自相关轴承生产企业。其中存在缺陷的轴承个数为 1 679 个(主要缺陷为凹坑的有 431 个,破损的有 426 个,划痕的有 412 个,锈蚀的有 410 个)。利用本文搭建的单工位轴承外表面缺陷检测系统中的成像模块,并将计算决策模块的状态调整为调试状态,同时将轴承进行旋转来实现数据增强,从

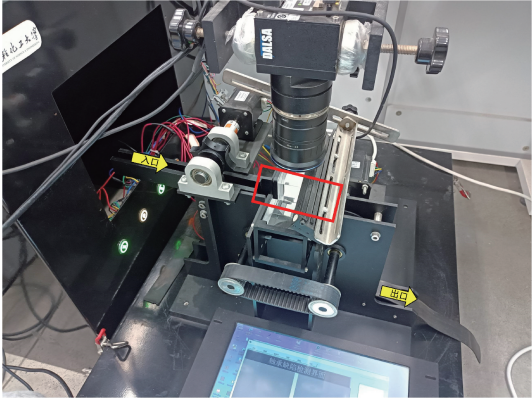


图 11 轴承表面缺陷检测系统实物图

Fig. 11 Physical image of bearing surface defect detection system

而收集了 4 000 张图片。其中包含缺陷图片为 3 200 张(凹坑、破损、划痕、锈蚀各 800 张),无缺陷图片 800 张。最后按 6:2:2 比例划分训练集、验证集、测试集。图 12 为部分数据集的展示。

表 1 单工位轴承外表面缺陷检测系统配置表
Table 1 Configuration table of single-station bearing outer surface defect detection system

参数	配置
操作系统	Windows 10
CPU	Intel i7-8700
相机	DALSA SG-11-02K0-00-R 线阵相机
镜头	VS-25085/C
光源	LDB-15034-B 蓝色条形光源
光学器件	镀镍直角三棱镜 x 2

由图 13 可看出,相对于面阵相机采集系统(如图 13(a)~(c)所示,本文的采集系统仅用一个工位一个线阵视觉传感器即可采集到轴承的外表面(如图 13(d)所示),避免多传感器的相机敏感度不同、光照强度不同、多图片匹配、外表面采集不全等多个传感器会出现的问题^[20]。具有光照强度统一、视觉信息高度集成、采集触发易协调等优点。同时,将轴承的圆形缺陷转换成矩形区

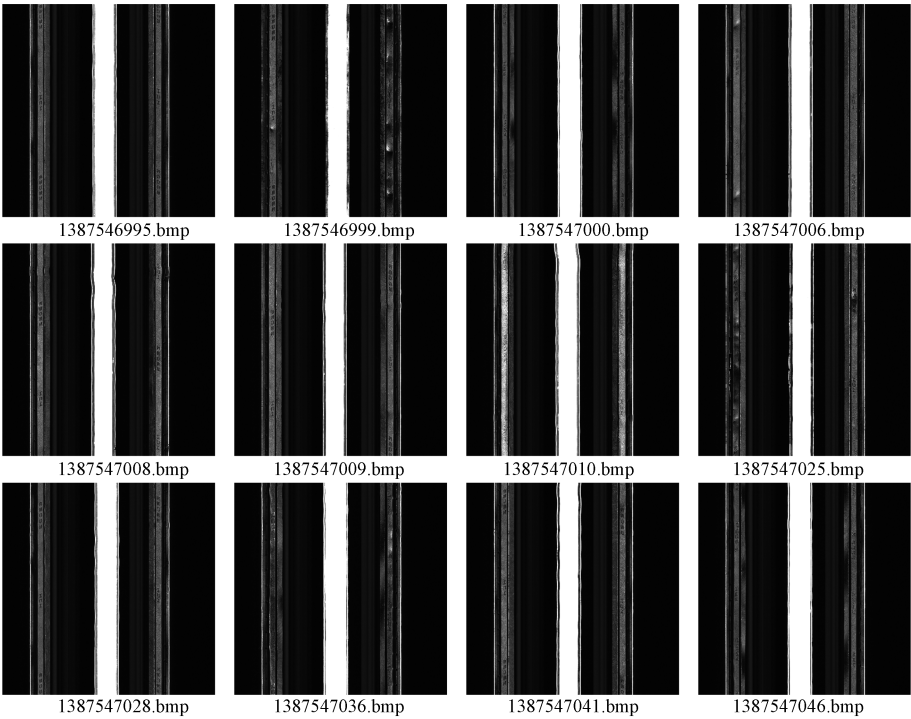


图 12 轴承数据集

Fig. 12 Dataset of bearing

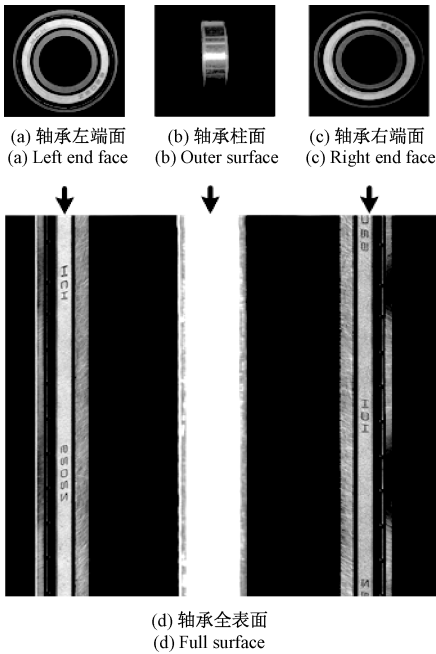


图 13 采集方式对比图

Fig. 13 Data collection method comparison figure

域,更易于如卷积等矩形特征提取手段进行特征提取。在该系统运行时,轴承从进入定位机构到离开定位机构的平均采集时间为 483 ms。

在测试本文提及的算法与模型时,为便于调试,均在如表 2 所示的深度学习实验平台进行测试。

表 2 芯片深度学习实验平台配置表

Table 2 Configuration table of deep learning experiment platform configuration table

参数	配置
操作系统	Windows 10
CPU	Intel i7-13700k
GPU	NVIDIA GeForce RTX 4070 Ti
RAM	32 G
训练框架	2.0.1+cu118

2.2 自适应畸变矫正算法

本文提出的自适应畸变矫正算法在实验中展现出较快的运行性能,平均处理时间为 17.46 ms,确保在不影响实时性的前提下有效提高所采集图像的几何形状精度。如图 14 所示,经过该算法处理后,存在畸变的轴承图像得到显著的形状精度提升,从而在送入模型进行检测时提高约 0.4% 的检测精度。

2.3 评价指标

为评估网络模型的性能,本文采用查准率(Precision)、查全率(Recall)、F1-score 3 个评价指标对本文模型进行精评价。但是考虑到有多种检测结果,故使用 macro 宏计算结果作为评价标准。计算原理如式(10)~(13)所示。

$$Precision_i = \frac{TP_i}{TP_i + FP_i}, P_{macro} = \frac{\sum Precision}{n} \quad (10)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i}, R_{macro} = \frac{\sum Recall}{n} \quad (11)$$

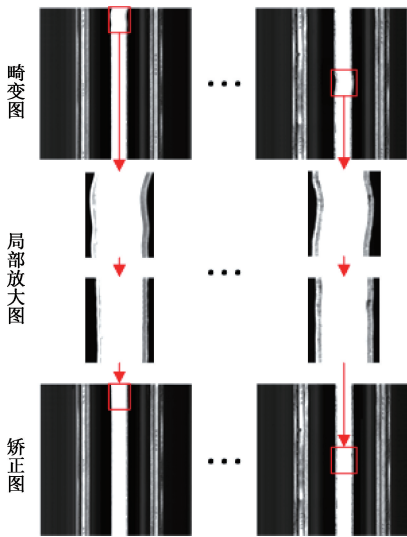


图 14 畸变矫正示例

Fig. 14 Distortion correction example

$$F1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{12}$$

$$F1_{macro} = 2 \times \frac{P_{macro} \times R_{macro}}{P_{macro} + R_{macro}} \tag{13}$$

式中: $Precision_i$ 表示类别 i 的精确率。 $Recall_i$ 表示类别 i 的召回率。 $F1\text{-score}$ 表示 F1 分数,是精确率和召回率的调和平均值。 TP_i 表示对于类别 i ,正确预测为正类的数量。 FP_i 表示对于类别 i ,错误地预测为正类的数量。

FN_i 表示对于类别 i ,错误地预测为负类的数量。下标带 $macro$ 的表示所有类别的平均值。

2.4 特征融合实验

为达成最有效的精度提升,本文探寻了不同特征融合方法对检测效果的影响,如表 3 所示。利用 BDDNet_O 模型(即去掉特征融合与多任务学习、仅保留轻量化功能的 BDDNet 模型)分别测试每种特征融合方式,观测精度变化。实验表明,模型利用 Concat 方法进行特征融合表现最佳,其次是 Add,最后是 Multi。

表 3 特征融合实验

Table 3 Feature fusion experiment

特征融合方式	Pmacro/%	Rmacro/%	F1macro
无	92.17	98.59	95.27
Concat	95.53	98.46	96.97
Add	94.09	97.86	95.94
Multi	92.22	98.47	95.24

从图 15 的验证集实验结果来看,Add 和 Multi 方法都出现过拟合的现象。这是因为部分特征信息在融合过程中消融了,保留的特征权重对训练集来说具有较强的可识别性。在未见过的验证集上泛化能力较差,导致验证集 Loss 升高。而 Concat 方法验证集 Loss 震荡下降趋势则反映丰富的特征对模型来说具有一定的挑战性,模型的训练会经历更复杂的动态调整。

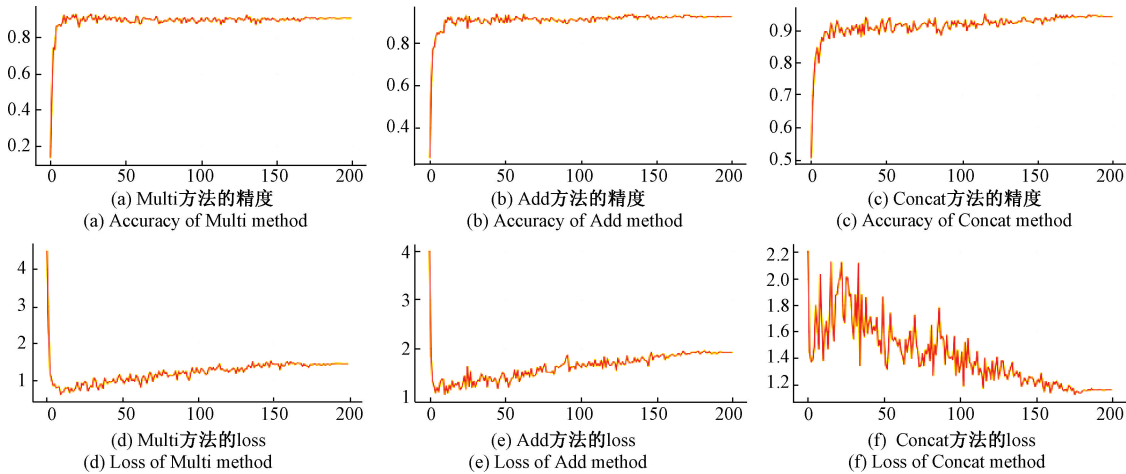


图 15 不同特征融合方式训练曲线

Fig. 15 Training curves of different feature fusion methods

因此说明,通过 Concat 方法将各尺度特征拼接在一起,模型不仅保留所有原始特征的信息,还能提供更多的浅层特征,使模型能够同时利用到各个尺度的信息,从而提高模型检测不同缺陷大小和形状的能力。而不像 Add 或 Multi 那样可能会丢失或压缩原始信息,因此可避免细节信息“侵占”语义信息的现象。

2.5 多任务学习实验

本文基于 concat 特征融合方法进行多任务学习实验,探究多种不同的子模型组合方式,实验结果如表 4 所示,其中 ‘+’ 号表示前后为不同的组合模型,数字代表子模型序号。

同时,从图 16 可看出,各种实验的收敛情况都较好且相似,但采用“(1,2)+(3,4)”优化方法的检测精度最高,

即子模型 1、2 组合其参数与 loss,子模型 3、4 组合其参数与 loss,并用两个优化器分别调节时,模型具有最佳性能。

表 4 多任务学习实验

Table 4 Multi-task learning experiment				
实验	优化方法	Pmacro/%	Rmacro/%	F1macro
1	无	95.53	98.46	96.97
2	1+2+3+4	97.58	97.96	97.77
3	1+2+(3,4)	96.85	98.98	97.90
4	(1,2)+3+4	97.70	98.23	97.96
5	(1,2)+(3,4)	98.58	98.48	98.53

这是因为它保持了细节特征与语义信息的完整性与独立性,使得模型能够在训练过程中更好地协调不同层次特征的学习过程,从而达到更好的性能。由于改动的是模

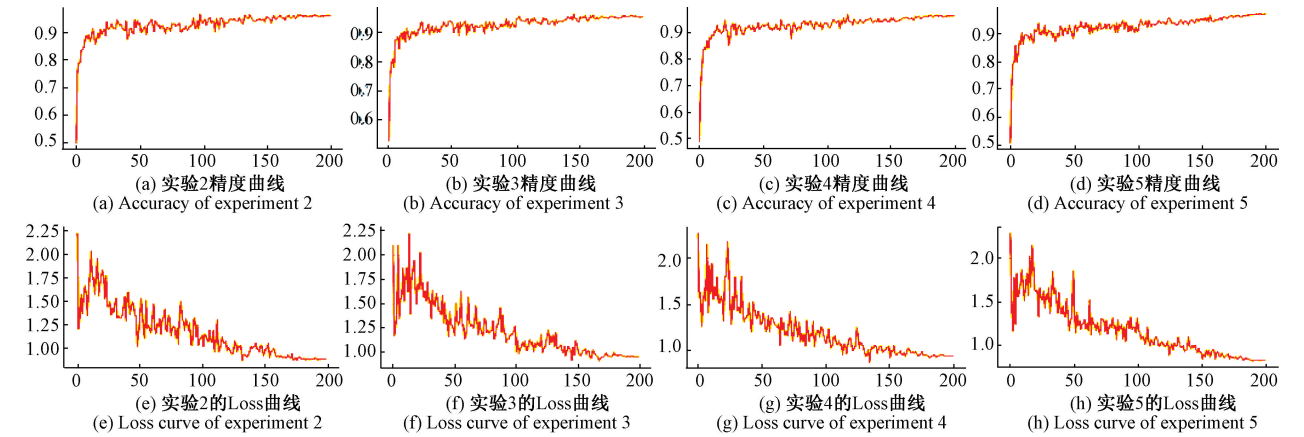


图 16 不同优化方式曲线

Fig. 16 Curves of different optimization methods

表 5 消融实验

Table 5 Ablation experiment										
实验	对比模型	BDDNet_O	畸变矫正	特征融合	多任务学习	Pmacro/%	Rmacro/%	F1macro	参数量/M	浮点运算量/G
1	✓					94.88	97.86	96.35	27.95	4.455
2	✓		✓			95.26	98.05	96.63	27.95	4.455
3		✓				92.17	98.59	95.27	11.66	1.610
4		✓		✓		95.53	98.46	96.97	18.67	1.618
5		✓		✓	✓	98.58	98.48	98.53	18.67	1.618
6		✓	✓	✓	✓	99.02	98.11	98.56	18.67	1.618

2.7 模型对比实验

为验证本文提出的 BDDNet 模型有效性以及验证 ConvNeXt 网络模型的性能,本文将轴承数据集送入 ConvNeXt-Tiny、Vision Transformer 与 Swin Transformer 模型,试验各个模型的性能,结果如表 6 所示。

型训练方法,模型速度没有受到影响,相比于没有采用优化训练方法的模型来说,精度提高了 3.05%。

2.6 消融实验

为验证所提出的自适应畸变矫正算法与 BDDNet 网络模型有效性,本文以 ConvNeXt-Tiny 网络为对比模型,分别测试 BDDNet_O 模型检测效果、有无畸变矫正的模型检测效果、添加特征融合方法的 BDDNet_O 模型检测效果、使用了多任务学习训练策略的 BDDNet_O 模型检测效果。实验结果如表 5 所示(不考虑自适应畸变矫正算法中的参数量与浮点运算量)。

可以看出,各方法对模型检测性能都有所提升。自适应畸变矫正算法通过矫正图形中的形变,改善模型输入质量,使得模型精度提高约 0.4%。轻量化的 BDDNet_O 结合 Concat 的特征融合方法、多任务学习的训练策略,使得模型性能进一步提升。

表 6 模型对比实验

Table 6 Model comparison experiments			
模型	Pmacro/%	Rmacro/%	F1macro
BDDNet	99.02	98.11	98.56
ConvNeXt-Tiny	94.88	97.86	96.35
Vision Transforme	95.36	96.20	95.78
Swin Transformer	94.49	97.35	95.90

由上表可知,ConvNeXt-Tiny 综合表现相对于 Vision Transformer 与 Swin Transformer 模型来说是最优的。而本文的 BDDNet 经过各个改进方法,性能已经超过了所述的 3 个模型。

同时,为了得知 BDDNet 在低性能计算机上的表现,本文在表 1 与表 2 两套设备上推理时间的实验。实验结果如表 7 所示(单位为 ms · frame⁻¹)。

表 7 推理时间对比实验

Table 7 Inference time comparison experiment

实验平台	深度学习		单工位轴承外表面	
	实验平台		缺陷检测系统	
实验设备	CPU	GPU	CPU	GPU
ConNeXt-Tiny	47.58	3.237	154.81	—
BDDNet	22.82	1.840	72.67	—

由表 7 与表 5 可知,BDDNet 相比于 ConvNeXt-Tiny 来说,精度提升 4.14%,参数量减少 33%,运算量减少 63.7%,推理时间也大幅缩减。在仅依靠 i7-8700cpu 的情况下,整个单工位轴承外表面缺陷检测系统从采集到出检测结果的平均运行时间为每个 0.735 s。

3 结 论

本文针对轴承外表面缺陷检测中存在的图像采集困难与检测速度慢的问题,提出了一种新颖的快速准确检测系统。该系统通过单工位、单次曝光的视觉信息采集方法,实现了对轴承全表面信息的高效获取,确保了光照强度的一致性和视觉信息的高度集成,大幅缩短了采集时间;并引入了自适应畸变矫正算法解决采集过程中随机出现的畸变问题,从而为后续的缺陷检测提供了高质量的数据输入,进一步提高了检测精度。

在此之上,本研究设计并搭建了轻量化轴承表面缺陷检测网络 BDDNet,通过优化网络结构和细节信息检测策略,使得模型在保持高精度的同时,显著降低了计算需求,满足了工业环境下实时在线检测的要求。特别是,通过将网络模型细分为多个子模型,并实现这些子模型间的协同学习,有效避免了局部最优解的问题,提升了整体检测性能。实验结果验证了所提系统的优越性,不仅实现了快速完整的表面信息采集,而且 BDDNet 在检测精度上达到了 99.02%。在低性能计算机中,每个轴承的平均处理时间为 0.735 s。相比现有技术有明显提升。

尽管本研究在轴承外表面缺陷检测方面取得了显著进展,但仍存在一些局限性,特别是在检测精度方面有进一步提升的空间。未来的研究可以通过优化算法、探索更深或更复杂的网络架构并充分利用新的计算平台来进一步提升检测精度。

参考文献

[1] YADAV E, CHAWLA V K. An explicit literature review on bearing materials and their defect detection techniques[J]. Materials Today: Proceedings, 2022, 50: 1637-1643.

[2] 姚蔚峰,袁巨龙,钟美鹏,等. 圆柱滚子外圆精密加工技术综述[J]. 中国机械工程, 2019, 30(10): 1195-1206.

YAO W F, YUAN J L, ZHONG M P, et al. Review on precision machining technology for outer diameters of cylindrical rollers [J]. China Mechanical Engineering, 2019, 30(10):1195-1206.

[3] 张炎亮,回彦静,王研迪. 基于 IESOA-BP 的滚动轴承故障诊断[J]. 电子测量技术,2024,47(14):35-41.

ZHANG Y L, HUI Y J, WANG Y D. Fault diagnosis of rolling bearing based on IESOA-BP[J]. Electronic Measurement Technology, 2024, 47(14): 35-41.

[4] 廖达海,殷明帅,罗宏斌,等. 基于剪切波变换对 Si_3N_4 陶瓷轴承内圈沟道表面缺陷检测的分析[J]. 航空动力学报,2024,39(1):231-239.

LIAO D H, YIN M SH, LUO H B, et al. Surface defect detection and analysis of Si3N4 ceramic bearing inner ring raceway based on shearlet transform[J]. Journal of Aerospace Power, 2024,39(1):231-239.

[5] MA J, HU S, FU J, et al. A hierarchical attention detector for bearing surface defect detection[J]. Expert Systems with Applications, 2024, 239: 122365.

[6] JIANG Y, HU K, ZHANG X, et al. A saturation channel detection method for surface defects of silicon nitride bearing rollers based on adaptive gamma correction-edge threshold segmentation coupling algorithm [J]. Materials Today Communications, 2023, 36: 106397.

[7] 陈仁祥,张雁峰,徐向阳,等. 基于子空间域对抗判别网络的不同型号滚动轴承剩余寿命预测[J]. 仪器仪表学报,2024,45(3):119-127.

CHEN R X, ZHANG Y F, XU X Y, et al. Remaining life prediction of different types of rolling bearings based on subspace domain adversarial discrimination network [J]. Chinese Journal of Scientific Instrument, 2024,45(3):119-127.

[8] DONG F, YANG H, DU H, et al. Triboelectric nanogenerator-embedded intelligent bearing with rolling ball defect diagnosis via signal decomposition and automated machine learning[J]. Nano Energy, 2024, 119: 109072.

[9] 杨冬毅,黄丹平,徐佳乐,等. 维度分割法轴承全表面缺陷检测[J]. 计算机工程与应用,2023,59(24):

- 176-184.
- YANG D Y, HUANG D P, XU J L, et al. Bearing full surface defect detection by dimension segmentation method[J]. Computer Engineering and Applications, 2023, 59(24): 176-184.
- [10] YU D, ZHU Z, MIN J, et al. Multi-scale decomposition enhancement algorithm for surface defect images of Si3N4 ceramic bearing balls based on stationary wavelet transform[J]. Advances in Applied Ceramics, 2021, 120(1): 47-57.
- [11] LI X, WANG Y, YAO J, et al. Multi-sensor fusion fault diagnosis method of wind turbine bearing based on adaptive convergent viewable neural networks[J]. Reliability Engineering & System Safety, 2024, 245: 109980.
- [12] SHEN S, LU H, SADOUGHI M, et al. A physics-informed deep learning approach for bearing fault detection[J]. Engineering Applications of Artificial Intelligence, 2021, 103: 104295.
- [13] 袁天乐, 袁巨龙, 朱勇建, 等. 基于改进 YOLOv5 的推力球轴承表面缺陷检测算法[J]. 浙江大学学报(工学版), 2022, 56(12): 2349-2357.
- YUAN T L, YUAN J L, ZHU Y J, et al. Surface defect detection algorithm of thrust ball bearing based on improved YOLOv5 [J]. Journal of Zhejiang University (Engineering Science), 2022, 56 (12): 2349-2357.
- [14] 钱佳立, 陆惠宗, 袁巨龙, 等. 基于光学原理的轴承球体表面缺陷检测方法研究[J]. 表面技术, 2018, 47 (10): 309-314.
- QIAN J L, LU H Z, YUAN J L, et al. Inspection of the surface defects of bearing ball based on optical theories [J]. Surface Technology, 2018, 47 (10): 309-314.
- [15] KANG Y, CHEN G, WANG H, et al. Fault anomaly detection method of aero-engine rolling bearing based on distillation learning[J]. ISA Transactions, 2024, 145: 387-398.
- [16] 张金汇, 谢林柏. 基于改进域对抗网络的轴承故障迁移诊断方法[J]. 电子测量与仪器学报, 2022, 36(11): 107-115.
- ZHANG J H, XIE L B. Bearing fault migration diagnosis method based on improved domain adversarial network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (11): 107-115.
- [17] LI SH CH, XUAN J P, ZHANG Q, et al. Open set transfer learning for bearing defect recognition based on selective momentum contrast and dual adversarial structure [J]. Advanced Engineering Informatics, 2024, 62: 102641.
- [18] 唐震, 彭业萍, 王伟江, 等. 融合 Hough 直线检测和 Grab-cut 的风机叶片自适应分割方法[J]. 电子测量与仪器学报, 2021, 35(4): 161-168.
- TANG ZH, PENG Y P, WANG W J, et al. Adaptive segmentation method for wind turbine blades combining Hough line detection and Grab-cut algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(4): 161-168.
- [19] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11976-11986.
- [20] 徐佳乐, 黄丹平, 廖世鹏, 等. 基于线扫描技术的轴承表面缺陷检测方法研究[J]. 中国测试, 2022, 48 (11): 88-94.
- XU J L, HUANG D P, LIAO SH P, et al. Study on detection method of bearing surface defect based on line scanning technology[J]. China Measurement & Test, 2022, 48(11): 88-94.

作者简介

蔡炳彬, 硕士研究生, 主要研究方向为机器视觉、深度学习。

E-mail: 1303461344@qq.com

黄丹平(通信作者), 博士, 教授, 主要研究方向为视觉系统、智能传感与检测技术、信号处理技术和自动化技术。

E-mail: hdpvx2025@suse.edu.cn