

DOI: 10.13382/j.jemi.B2104310

基于深度学习网络的轴承工件自动检测*

谷峥嵘 魏利胜

(安徽工程大学 电气工程学院 芜湖 241000)

摘要:针对实际生产中轴承滚子原始故障数据量少,数据集不平衡的问题,提出一种数据增强策略对原始的数据集进行扩充,并结合 U-Net 框架和轻量级深度学习模型构建了一个端到端的轴承滚子语义分割模型方法。通过结合 U-Net 框架和轻量级深度学习模型 MobileNetV1、DenseNet121 构建了端到端的轴承滚子语义分割模型 LS-MobileNetV1、LS-DenseNet121,将所提模型基于迁移学习策略进行了训练,与其他模型进行对比实验分析。结果表明,与现有方法相比,本文方法在具有更少参数量的情况下实现了更高的分割精度与更具鲁棒性的检测效果,验证了所提方法的有效性。

关键词: 轴承滚子;数据增强;深度学习模型;语义分割;迁移学习

中图分类号: TH85⁺5 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Automatic detection for bearing roller based on deep learning network

Gu Zhengyan Wei Lisheng

(School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China)

Abstract: Aiming at the problem of small amount of original fault data and unbalanced data set of bearing rollers in actual production, a data enhancement strategy was proposed to expand the original bearing image data set, and combined with the U-Net framework and lightweight deep learning model to construct an end-to-end bearing roller semantic segmentation model method. By combining the U-Net framework and lightweight deep learning models MobileNetV1 and DenseNet121, the end-to-end bearing roller semantic segmentation models LS-MobileNetV1 and LS-DenseNet121 are constructed, the proposed models are trained based on the transfer learning strategy, and compared with other models for experimental analysis. The results show that compared with the existing methods, the method in this paper achieves higher segmentation accuracy and more robust detection results with few parameters, which verifies the effectiveness of the proposed method.

Keywords: bearing roller; data enhancement; deep learning model; semantic segmentation; transfer learning

0 引言

随着时代的发展,科学技术的发展也是日新月异,这些年我国的工业制造业进步很大,而轴承在工业制造中是一种极为重要的部件,其质量问题一直是人们关注的问题^[1]。但是在工业生产中,轴承工件的许多检测工作仍通过人工进行,这在很大程度上限制了其生产效率,同时也增加的人工失误所带来的相关风险^[2]。因此研究如何利用机器视觉技术对轴承工件进行快速有效地检测以

推动其自动化应用具有重要的实际意义。

随着我国工业生产趋向高精尖化,对轴承产品的质量要求也逐渐提高^[3]。使用质量不合格的轴承会损害工业产品的机械性能、使用寿命等指标^[4-5]。人工进行轴承的质量检测的受影响因素较多,也增加了人工失误所带来的风险,检测精度和效率也受到了限制。因此,研究怎样结合机器视觉技术并实现轴承工件检测的自动化,对工业生产有着重要意义。

在机器视觉领域,有关轴承的表面缺陷检测问题是研究的热门问题,国内外相关专家学者对这类问题进行

了大量研究,并取得了丰富的成果^[6-9]。段志达等^[10]提出一种基于霍夫变换圆检测和边缘模板匹配的轴承滚子检测方法,实验表明该方法较传统阈值分割方法准确率有较大提高。Zhang 等^[11]提出了一种基于复合多尺度模糊熵和集成支持向量机的轴承故障诊断方法,实验表明该方法能够有效地区分不同的滚动轴承的故障类别和故障的严重程度。Sun 等^[12]提出了一种将机器视觉与人工智能网络结合的智能系统,以检测热熔丝生产过程中常见的黑点,小头等缺陷;Chen 等^[13]设计了一种图像采集装置并使用改进的灰度补偿方法来处理图像的灰度值不均问题,最后利用直方图聚类方法对缺陷进行分割,该方法识别准确率和效率较高。文生平等^[14]提出了一种基于最大类间方差法和局部阈值算法的缺陷分割方法,对分割后图像进行特征提取并进行支持向量机(SVM)分类,实验表明该方法精度较高,适应性强。Shi 等^[15]提出了一种改进的光学缺陷分割算法,使用 Gabor 滤波器,核主成分分析(KPCA)方法和极限学耳机(ELM)神经网络的组合对轴承表面缺陷进行分类,实验表明该方法能够保持较高的识别率。陈昊等^[16]提出了一种基于图像光流的轴承滚子表面缺陷的检测方法,实验表明该方法分割效果较好但是实时性较差。魏利胜等^[17]提出了一种融合单应性约束 SIFT 的轴承滚子检测方法,实验表明该方法检测正确率比传统分割方法提高了 33%。郝勇等^[18]提出一种结合轴承纹理特征和支持向量机模型的识别方法,实验结果表明该方法能较好的识别出歪斜轴承,识别准确率较高。徐建桥等^[19]提出了一种基于规范化样本拆分的轴承缺陷检测方法,在 Resnet18、

GoogLeNet 等网络上取得了较好的检测效果。毛昭辉等^[20]使用深度置信网络检测轴承表面的细小缺陷,准确率和效率较高。Olaf 等^[21]提出了一种网络训练策略,通过数据增强更有效地使用样本,实验表明该网络架构可以使用较少的样本获得较好的分割性能。

以上专家学者在轴承检测和缺陷检测方面进行了研究,且取得了丰硕成果。但是主要使用阈值分割方法或者所用模型需要较多的样本量,本文在以上研究的基础上,基于轻量级深度学习模型对轴承滚子的语义分割进行了研究,通过运用数据增强策略来缓解模型可能出现的过拟合现象,并且在 U-Net 框架下,基于轻量级模型 MobileNetV1 和 DenseNet121 构建了一个端到端的语义分割模型,同时利用迁移学习策略对所提模型进行训练,以实现较高的检测准确率。

1 基于深度学习网络的轴承工件检测原理

为了保证模型精度的情况下同时保持模型的轻量化,本文在文献[14]U-Net 架构的基础上,通过结合数据增强策略、迁移学习方法,并引入 MobileNet、DenseNet 模型的特征提取结构重新设计一种轻量级的语义分割模型 LS-MobileNetV1(基于 MobileNetV1 特征提取模块)、LS-DenseNet 121(基于 DenseNet121 特征提取模块),然后分别使用不同的损失函数和不同的特征提取模块对模型进行训练,在保证模型参数量较低的同时实现了较高的分割精度,模型结构如图 1 所示。




图1 本文所提轴承滚子语义分割模型框架

Fig. 1 Semantic segmentation model framework of the proposed bearing roller

基于深度学习网络的轴承工件检测分割方法主要包括数据集构建、图像增强、模型训练以及分割预测 4 个部分。1) 数据集构建,根据轴承图像原始数据,标注轴承滚子、保持架支柱掩码,构建训练模型所需的数据集;2) 图

像增强,在步骤 1) 构建的分割数据集中,利用数据增强进行扩展,并将其分为训练集,验证集和测试集,以准备进行模型训练;3) 模型训练,构建语义分割模型,加载预训练权重参数,并基于训练集和验证集对模型进行训练;

4) 分割预测, 基于融合的方法对训练的模型在测试集上进行性能评估。

1.1 数据预处理

在工业生产中, 一般只保留产品的原始图像信息, 而语义分割模型训练对输入的数据格式有一定的要求, 因此要对原始数据集进行预处理, 主要包括数据集的创建和增强。

数据集创建采用 Labelme 软件手动选择目标区域进行掩码的绘制与自动生成, 效果如图 2 所示。




图 2 轴承滚子、保持架分割图像标注结果

Fig. 2 Marking results of segmented images of bearing rollers and cages

由于较少的数据集可能导致模型发生过拟合, 这不利于模型最终性能的评估。本文使用数据增强技术来扩展原始数据集, 通过随机拉伸, 随机缩放, 亮度改变, 对比度改变和颜色改变之类的操作来增加原始数据集的数量, 并提高模型的鲁棒性。相关效果如图 3 所示。




图 3 不同方式的数据增强效果

Fig. 3 Different ways of data enhancement effect diagram

通过数据增强处理将原始的 80 张轴承保持架支柱图像和 50 张轴承滚子训练集图像分别扩充至 4 641、4 009 张, 其中 4/5 作为训练集, 1/5 作为验证集, 供模型训练使用。

1.2 模型构建与训练评估

通常情况下, 轻量级模型由基础模块组成, 基础模块由少量网络层组成。这些网络层主要包括空间维度和通道方面的操作, 这些操作包括深度可分离卷积、组卷积、通道分离、通道混洗、通道拼接以及残差连接等。其中, 深度可分离卷积和标准卷积的区别如图 4 所示。




图 4 标准卷积和深度可分离卷积示意图

Fig. 4 Schematic diagram of standard convolution and depth separable convolution

从图 4(b) 可知, 深度可分离卷积可以分为深度卷积和逐点卷积, 分别对应空间和通道上的操作。首先将卷积一次插入到输入特征图像的分离通道中, 获得与输入特征图具有相同深度的输出特征图, 然后在其上执行逐点卷积操作, 从而得到最终的输出特征图。以图 4(a) 所展示的标准卷积为例, 假设输入特征图尺寸为 $H \times W \times N$, 输出特征图大小为 $H \times W \times N$, 卷积核大小为 $K \times K$, 则一个标准卷积层的参数量为 $K^2 \times W \times N$, 而使用深度可分离卷积层的参数量 $K^2 \times N + 1^2 \times N \times W$, 由此可知, 深度可分离卷积只有标准卷积的参数量的 $1/W + 1/K^2$ 。在 MobileNetV1 中, 通过使用大量的深度可分离卷积, 模型的大小有了显著的减小, 同时保持了较好的模型精度。在 DenseNet 中, 参数量的降低主要通过模型中稠密连接模块、过度模块的 $H \times W \times N$ 卷积实现, 其中稠密连接模块定义如下:

$$x_i = H_i([x_0 + x_1, \dots, x_{i-1}]) \quad (1)$$

式中: x_i 表示稠密连接模块中第 i 层的特征图, H_i 表示一个组合函数, 主要包括了 ReLU、Conv 1×1 和 Conv 1×1 操作, 可以发现, 每层网络的输入是之前各网络层输出的结合, 这种特征复用的方式使得模型能够提取到更加丰富的特征信息, 从而提高模型的特征分辨能力。

基于 MobileNetV1 特征提取模块构建的分割网络编码器具体的结构如表 1 所示。当深度可分离卷积步长为 1 时, 表明输出和输入的尺寸相同, 当步长为 2 时, 表明输出是输入尺寸的一半。在解码器模块中, 与输出特征

相连的分别是编码器的 Conv 3×3, Depthwise Separable Block2、3 和 Depthwise Separable Block4。

表 1 LS-MobileNetV1 的组成结构(基于 MobileNetV1)
Table 1 The structure of LS-MobileNetV1
(based on MobileNetV1)

操作	参数	输入大小
卷积	3×3, s=1	224×224
Depthwise Separable Block1	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=1$	112×112
	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=2$	
Depthwise Separable Block2	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=1$	56×56
	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=2$	
Depthwise Separable Block3	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=1$	28×28
	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=2$	
Depthwise Separable Block4	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=1$	14×14
	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=2$	
Depthwise Separable Block5	$\begin{bmatrix} 3\times3 \text{ dw conv} \\ 1\times1 \text{ conv} \end{bmatrix}, s=1$	7×7

基于 DenseNet121 特征提取模块构建的分割网络编码器的具体结构如表 2 所示。与输出特征相连的分别是编码器的 Conv 7×7, Dense Block1, Dense Block2, Dense Block3. block 3×3。

表 2 LS-DenseNet121 的组成结构(基于 DenseNet121)
Table 2 The structure of LS-DenseNet121
(based on DenseNet121)

操作	参数	输入大小
卷积	7×7 conv, s=2	224×224
pooling	3×3 max pool, s=2	112×112
Dense Block1	$\begin{bmatrix} 1\times1 \text{ conv} \\ 3\times3 \text{ conv} \end{bmatrix} \times 6, s=1$	56×56
Transition Layer1	1×1 conv	56×56
	2×2 average pool, s=2	
Dense Block2	$\begin{bmatrix} 1\times1 \text{ conv} \\ 3\times3 \text{ conv} \end{bmatrix} \times 12, s=1$	28×28
Transition Layer2	1×1 conv	28×28
	2×2 average pool, s=2	
Dense Block3	$\begin{bmatrix} 1\times1 \text{ conv} \\ 3\times3 \text{ conv} \end{bmatrix} \times 24, s=1$	14×14
Transition Layer3	1×1 conv	14×14
	2×2 average pool, s=2	
Dense Block4	$\begin{bmatrix} 1\times1 \text{ conv} \\ 3\times3 \text{ conv} \end{bmatrix} \times 16, s=1$	7×7

基于 MobileNetV1 特征提取模块构建的分割网络的最后一个轻量级卷积模块包含了 Depthwise Separable Block4 and Depth-wise Separable Block5, 而基于 MobileNetV1 特征提取模块构建的分割网络的最后一个轻量级卷积模块包含了 Transition Layer3、Dense Block4 (图 1)。

在工业生产中,很难找到适合深度学习模型训练的标准数据,如果从 0 开始训练,往往会耗时过长或者性能过差,为了在数据集较少的情况下减少的耗时,提高性能,因此使用基于迁移学习策略的模型训练方法。首先将预训练模型权重写入到分割模型的编码器所对应的网络层中,其次使用 Adam 优化器训练网络,学习率为 0.001,在 4 个连续的迭代训练周期内,若模型的损失值低于预期数值,则将学习率改为前一轮学习率的 1/2。通过学习率自衰减,能提高模型收敛速度和精度。将模型训练 50 轮,损失函数使用 BCE Dice Loss,公式如下:

$$S_1 = \sum_{i=1}^w \sum_{j=1}^h P_{ij} Y_{ij} \tag{2}$$

$$S_2 = \sum_{i=1}^w \sum_{j=1}^h Y_{ij} \tag{3}$$

$$S_3 = \sum_{i=1}^w \sum_{j=1}^h P_{ij} \tag{4}$$

$$L_{Dice} = 1 - (2 \cdot S_1 + \epsilon) / (S_2 + S_3 + \epsilon) \tag{5}$$

式中: P_{ij} 为分割网络的预测输出概率图; Y_{ij} 为分割网络的真实分割图。通过将 BCE Loss 和 Dice Loss 进行组合,即可以构成 BCE Dice 损失函数,计算公式如下:

$$L_{Cross} = \frac{1}{w \times h} \sum_{i=1}^w \sum_{j=1}^h [Y_{ij} \ln P_{ij} + (1 - Y_{ij})(1 - \ln P_{ij})] \tag{6}$$

$$L_{BCEDice} = L_{Dice} + \partial L_{Cross} \tag{7}$$

式中: ∂ 为比例因子,表示不同交叉熵损失函数占总损失函数的比例。

本文所提的方法在独立的具有不同检测背景的轴承图像测试集上进行性能测试(包含 20 张轴承滚子和 10 张轴承保持架支柱图像),模型评估指标使用准确率(AC)、灵敏度(SE)、特异度(SP)、JA、DI、在像素层面对模型进行评估,能够较好的反映模型的整体性能,各评估指标相关定义如下:

$$AC = (S_{tp} + S_{tn}) / (S_{tp} + S_{tn} + S_{fp} + S_{fn}) \tag{8}$$

$$SE = S_{tp} / (S_{tp} + S_{fn}) \tag{9}$$

$$SP = S_{tn} / (S_{tn} + S_{fp}) \tag{10}$$

$$JA = S_{tp} / (S_{tp} + S_{fp} + S_{fn}) \tag{11}$$

$$DI = 2S_{tp} / (2S_{tp} + S_{fp} + S_{fn}) \tag{12}$$

式中: S_{tp} 为真阳性像素的个数; S_{tn} 为真阴性像素的个数; S_{fn} 为假阴性像素的个数; S_{fp} 为假阳性像素的个数。

2 实验验证及结果分析

2.1 不同特征提取模块对所提方法性能的影响

为了提升语义分割的效果,通常会使用具有更多和更宽网络层的模型,但这会导致模型的参数量变多,从而对计算机的硬件要求也会变高,使得模型训练更加困难。因此本文使用轻量级的网络 LS-MobileNetV1、LS-DenseNet121。此外,为了验证本文所提的方法,在相同实验条件下,基于 InceptionV 构建的具有较大参数数量的语义分割模型为 LS- InceptionV3,而基于 ResNext50 构建具有较大参数数量的语义分割模型为 LS- ResNext50。实验结果对比如表 3 所示。

由表 3 可以发现,相比原始 U-Net,所提模型 LS-MobileNetV1、LS-DenseNet121 在 DI、JA 指标上分别提高

表 3 不同特征提取模块下分割模型的性能对比

Table 3 Performance comparison of segmentation models under different feature extraction modules

模型	AC	DI	JA	SE	SP
U-Net	0.902	0.826	0.704	0.755	0.998
LS-InceptionV3	0.968	0.879	0.784	0.881	0.998
LS-ResNext50	0.977	0.882	0.789	0.898	0.997
LS-MobileNetV1	0.982	0.888	0.800	0.939	0.848
LS-DenseNet121	0.978	0.900	0.819	0.900	0.997
Fusion	0.984	0.910	0.834	0.945	0.993

注:加粗表示在该指标下效果最佳

6.2%、9.6%、7.4%、11.5%。在相同架构下,相比较大模型 LS-ResNext50,所提 LS-MobileNetV1、LS-DenseNet121 在 DI、JA 指标上分别高出 0.5%、0.6%、0.1%、1.18%,通过进一步结合模型融合策略后,在 DI、JA 指标上分别高出 0.7%、1.28%。模型训练期间的相关损失曲线如图 5 所示。




图 5 本文方法训练损失、学习率曲线

Fig. 5 Training loss and learning rate curve of proposed method

2.2 不同损失函数对模型性能影响

为了研究不同损失函数对模型性能的影响,同时考虑到数据集中样本存在类别不平衡现象,在相同训练条

件下,使用 Focal loss 作为损失函数来训练对所提的模型,实验的结果如表 4 所示。

表 4 不同分割损失函数的模型性能

Table 4 Model performance of different segmentation loss functions

方法		AC	DI	JA	SE	SP
BCE Dice Loss	LS-MobileNetV1	0.982	0.888	0.800	0.939	0.848
	LS-DenseNet121	0.978	0.900	0.819	0.900	0.997
Focal Loss	LS-MobileNetV1	0.974	0.888	0.800	0.829	0.998
	LS-DenseNet121	0.966	0.879	0.784	0.844	0.998

注:加粗表示在该指标下效果最佳

由表 4 可见,相比 BCE Dice 损失函数,Focal Loss 在整体评估指标上并未出现提升效果,且相对于 LS-MobileNetV1、LS-DenseNet121 而言,在评估指标 AC 上分别下降 0.8%、1.2%。一个可能的原因是使用 Focal Loss 存在训练不稳定的情况,使得模型难以收敛至最佳效果,同时,Focal Loss 中平衡正负样本的因子过度的调节作用也会导致其相关指标得分低于 BCE Dice Loss。

2.3 特征可视化与检测结果分析

为了进一步验证所提模型学习到了有效的轴承滚子

特征表征模式,将网络最后一层卷积的输出进行了可视化,如图 5 所示。从图 5 可以发现,所选的部分测试图像包含了各种复杂的检测情况,如光照不均、光照过强或过暗、颜色变化较大以及轴承尺度变换等,在这些检测环境下,所提 LS-MobileNet 和 LS-DenseNet121 的输出概率图呈现出较好的分割结果,分割出的区域主要集中在轴承滚子区域,并且通过模型融合策略可以进一步改善分割鲁棒性,说明模型学习到了有效的轴承特征表征模式,可以在不同的检测环境下较为准确的分割出轴承滚子。




图 6 不同语义模型输出的概率图可视化结果

Fig. 6 Visualization results of probability graphs output by different semantic models

不同语义模型输出的概率图可视化结果如图 6 所示。图 6 中点表示轴承滚子的定位点,对于本文方法和文献[21]方法是通过计算分割图掩码边界的重心得得到,对于文献[5]方法,则通过计算灰度投影统计特征点的波谷位置坐标得到。点表示轴承滚子预测位置的中心、方框表示真实的位置框。复杂背景下不同方法的轴承滚子检测效果对比如图 7 所示。从检测效果可以发现,本文方法在不同的复杂检测环境下均实现了稳定的轴承滚

子检测,而文献[21]在图像局部光照变换较为剧烈的情况下会因为无法有效分割出轴承滚子,导致检测失败,同样,文献[5]方法对于环境光变化较为缓和的情况下可以实现一定的检测率,然而当目标环境光和尺寸发生变化时则容易出现检测失败的现象,这是因为基于灰度投影统计特征点的检测效果易受局部光照变化的影响,同时,定位策略中投影点的波谷位置计算也需要手动选择参数,无法自适应发生变化的检测环境。




图 7 复杂背景下不同方法的轴承滚子检测效果对比

Fig. 7 Comparison of the detection results of different methods of bearing rollers in a complex background

3 结 论

由于工业流水线中轴承生产环境的复杂性以及生产

标准的逐步提高,传统机器视觉检测方法已经不能很好的适应实际检测要求。本文基于轻量级的深度学习模型,研究了轴承滚子的语义分割问题,通过运用数据增强策略来缓解模型可能出现的过拟合现象,并在 U-Net 框

架下,基于轻量级模型 MobileNetV1 和 DenseNet121 构建了一个端到端的语义分割模型,同时利用迁移学习策略对所提模型进行训练,模型评估结果表明,在不同的检测环境下,所提方法相比现有方法均实现了更好的分割精度和检测效果。如何在小数据集背景下,进一步降低模型的参数量以及提高模型的运行速度与精度,实现复杂环境下的轴承滚子检测和保持架支柱快速定位,这将是接下来进一步要研究的工作。

参考文献

- [1] 张明辉,王建武,张文,等. 机器视觉在轴承检测中的研究现状及发展趋势[J]. 机床与液压,2019,47(23): 183-189.
ZHANG M H, WANG J W, ZHANG W, et al. Research status and development trend of machine vision in bearing inspection [J]. Machine Tool & Hydraulics, 2019, 47(23): 183-189.
- [2] 李云朋,熊柳景,牛刚. 嵌入式轴承故障诊断系统的设计与实现[J]. 国外电子测量技术,2019,42(9): 107-111.
LI Y P, XIONG L J, NIU G. Design and implementation of embedded bearing fault diagnosis system[J]. Foreign Electronic Measurement Technology, 2019, 42(9): 107-111.
- [3] 吕宏政,陈仁文,张祥,等. 基于 VMD 交叉样本熵的旋翼桨叶故障诊断方法[J]. 电子测量技术,2019,42(9): 107-111.
LV H ZH, CHEN R W, ZHANG X, et al. Fault diagnosis method of rotor blade based on VMD and cross-sample entropy [J]. Electronic Measurement Technology, 2019, 42(9): 107-111.
- [4] 孙圆圆,李凯,牛泽. 钻杆表面缺陷检测的有限元分析[J]. 国外电子测量技术,2020,39(12): 1-5.
SUN Y Y, LI K, NIU Z. Finite element analysis of drill pipe surface defects detection [J]. Foreign Electronic Measurement Technology, 2020, 39(12): 1-5.
- [5] ABID A, HAQ Z U, KHAN M T. Fault detection using negative selection and genetic algorithms [J]. Instrumentation, 2019, 6(3): 39-51.
- [6] 宫文峰,陈辉,张美玲,等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报,2020,41(1): 195-205.
GONG W F, CHEN H I, ZHANG M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning[J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.
- [7] 唐波,陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.
- [8] 朱哈娜,刘慧明. 基于改进 VMD 与 GS_SVM 的轴承故障诊断[J]. 电子测量技术,2020,43(21): 71-76.
ZHU H N, LIU H M. Bearing fault diagnosis based on improved VMD and GS _ SVM [J]. Electronnic Measurement Tecoonocoy, 2020, 43(21): 71-76.
- [9] HU P F, HUANG H S, XIE Q S. The method research and technology implementation of eddy current hardness-sorting based on LS-SVM [J]. Instrumentation, 2020, 7(1): 13-23.
- [10] 段志达,魏利胜,刘小琿,等. 基于 Hough 变换圆检测和边缘模板匹配的轴承缺陷检测与定位[J]. 安徽工程大学学报,2020,35(4): 60-68.
DUAN ZH D, WEI L SH, LIU X H, et al. Bearing defect detection and location based on Hough transform circle detection and edge template matching[J]. Journal of Anhui Polytechnic University, 2020, 35(4): 60-68.
- [11] ZHENG J D., PAN H Y, CHENG J S. Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines[J]. Mechanical Systems & Signal Processing, 2017(85): 746-759.
- [12] SUN T H, TIEN F C, KUO R J. Automated thermal fuse inspection using machine vision and artificial neural networks [J]. Journal of Intelligent Manufacturing, 2016, 27(3): 639-651.
- [13] CHEN J, CHEN H, ZHANG B. An improved gray compensation method for surface defect detection of tapered roller[C]. International Conference on Computer Technology, Electronics and Communication (ICCTEC), 2017: 222-226.
- [14] 文生平,刘云明. 基于机器视觉的圆锥滚子外观缺陷检测系统研究[J]. 计算机测量与控制,2017,25(1): 40-43.
WEN SH P, LIU Y M. Research on inspection system of tapered roller's appearance defect based on machine vision [J]. Computer Measurement and Control, 2017, 25(1): 40-43.
- [15] SHI D, ZHOU J, XU J, et al. Machine vision-based segmentation and classification method for intelligent roller surface monitoring[C]. 2018 IEEE Smart World, 2018: 811-8117.
- [16] 陈昊,张奔,黎明,等. 基于图像光流的轴承滚子表面缺陷检测[J]. 仪器仪表学报, 2018, 39(6):

- 198-206.
CHEN H, ZHANG B, LI M, et al. Bearing roller surface defect detection based on image optical flow[J]. Chinese Journal of Scientific Instrument, 2018, 39(6): 198-206.
- [17] 魏利胜, 丁坤, 段志达, 等. 融合单应性约束 SIFT 特征匹配的轴承滚子检测[J]. 电子测量与仪器学报, 2019, 33(9): 107-113.
WEI L SH, DING K, WU H Y, et al. Bearing roller detection based on SIFT feature matching with homography constraints [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (9): 107-113.
- [18] 郝勇, 耿佩, 温钦华, 等. 滚动轴承保持架缺陷的图像处理及模式识别方法研究[J]. 仪器仪表学报, 2019, 40(9): 162-169.
HAO Y, GENG P, WEN Q H, et al. Research on image processing and pattern recognition of skew defect of antifriction bearing cage [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 162-169.
- [19] 徐建桥, 吴俊, 陈向成, 等. 基于规范化样本拆分的轴承缺陷检测[J]. 应用光学, 2021, 42(2): 327-333.
XU J Q, WU J, CHEN X CH, et al. Bearing defects detection based on standardized sample split[J]. Journal of Applied Optics, 2021, 42(2): 327-333.
- [20] 毛昭辉, 张庭. 火电机轴表面细小缺陷深度检测方法仿真[J]. 计算机仿真, 2020, 37(3): 409-413.
MAO ZH H, ZHANG T. Simulation of defect depth detection method for bearing surface of thermal power unit [J]. Computer Simulation, 2020, 37(3): 409-413.
- [21] OLAF R, PHILIPP F, THOMAS B. U-net: convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention MICCAI, 2015: 234-241.

作者简介



谷峥岩, 2019 年于安徽工程大学获得学士学位, 现安徽工程大学硕士研究生, 主要研究方向为图像识别与应用。

E-mail: guzhy97 @ 163. com

Gu Zhengyan received his B. Sc. degree in 2019 from Anhui Polytechnic University.

Now he is a M. Sc. candidate at Anhui Polytechnic University. His main research interests include image recognition and application.



魏利胜 (通信作者), 2001 年于安徽工程大学获得学士学位, 2004 年于中国航天科工集团 061 基地获得硕士学位, 2009 年于上海大学获得博士学位, 现为安徽工程大学教授、硕士生导师, 主要研究方向为图像识别与应用、嵌入式仪器仪表及系统、智能化

网络控制理论、系统和仿真。

E-mail: lshwei_11@ 163. com

Wei Lisheng (Corresponding author) received his B. Sc. degree in 2001 from Anhui Polytechnic University, M. Sc. degree in 2004 from China Aerospace Science and Industry Corporation 061 Base and Ph. D. degree in 2009 from Shanghai University. Now he is a professor and M. Sc. supervisor at Anhui Polytechnic University. His main research interests include image recognition and application, embedded instrumentation and system, intelligent network control theory, system and simulation.