

陈志阳, 樊重俊, 林子谦. 基于知识蒸馏的滚动轴承故障诊断分类研究[J]. 智能计算机与应用, 2025, 15(6): 102–107. DOI: 10.20169/j.issn.2095-2163.25030403

基于知识蒸馏的滚动轴承故障诊断分类研究

陈志阳, 樊重俊, 林子谦
(上海理工大学 管理学院, 上海 200093)

摘要: 滚动轴承故障诊断对工业设备的可靠性至关重要。传统方法着重于复杂故障模式在时域/频域特征提取、固定阈值判断、单一数据模式处理等方面的研究视角,但其线性模型、小样本适应性差、工况敏感性等问题导致精度受限,计算效率偏低。本文提出了一种基于知识蒸馏的卷积神经网络模型,用于提高滚动轴承故障诊断的分类精度和计算效率。首先,使用滚动轴承故障数据集进行特征提取,并构建了深度卷积神经网络作为教师模型和小型卷积神经网络作为学生模型。通过知识蒸馏技术,学生模型有效学习教师模型的判别能力,同时提升推理速度。实验结果表明,教师模型的分类准确率达到 97.2%,学生模型经过知识蒸馏优化后分类准确率提升至 95.8%,同时推理时间缩短至 0.9 s,参数量减少至 150 万,显著提高了计算效率和实时性。

关键词: 滚动轴承; 故障诊断; 知识蒸馏; 卷积神经网络; 深度学习; 特征提取

中图分类号: C931.6

文献标志码: A

文章编号: 2095-2163(2025)06-0102-06

Research on fault diagnosis and classification of rolling bearings based on knowledge distillation

CHEN Zhiyang, FAN Chongjun, LIN Ziqian

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Fault diagnosis of rolling bearing is very important to the reliability of industrial equipment. Traditional methods focus on complex fault modes in time domain/frequency domain feature extraction, fixed threshold judgment, single data mode processing, etc., but its linear model, poor adaptability of small samples, working condition sensitivity and other problems lead to limited accuracy and low computational efficiency. In this paper, a convolutional neural network model based on knowledge distillation is proposed to improve the classification accuracy and computational efficiency of rolling bearing fault diagnosis. Firstly, the rolling bearing fault data set is used for feature extraction, and a deep convolutional neural network is constructed as a teacher model and a small convolutional neural network as a student model. Through knowledge distillation technology, the student model can effectively learn the discriminant ability of the teacher model and improve the reasoning speed. The experimental results show that the classification accuracy of the teacher model reaches 97.2%, and the classification accuracy of the student model increases to 95.8% after knowledge distillation optimization. Meanwhile, the reasoning time is shortened to 0.9 seconds and the number of parameters is reduced to 1.5 million, which significantly improves the computing efficiency and real-time performance.

Key words: rolling bearing; fault diagnosis; knowledge distillation; convolutional neural network; deep learning; feature extraction

0 引言

滚动轴承作为机械设备中的核心部件,广泛应用于电力、冶金、航空航天等高负荷、高可靠性需求的工业领域。其长期运行中承受复杂动态载荷,且常处于恶劣工况,如高温、振动、润滑不足,导致故障

频发,严重威胁设备安全性与生产效率。因此,滚动轴承的故障诊断对保障设备安全运行、减少停机时间、降低维修成本意义重大。随着工业自动化和智能化的不断发展,对滚动轴承故障进行高效、准确的诊断成为机械领域的研究热点。

传统滚动轴承故障诊断方法依赖信号处理与物

作者简介: 陈志阳(1999—),男,硕士研究生,主要研究方向:人工智能理论及应用。

通信作者: 樊重俊(1963—),男,博士,教授,主要研究方向:人工智能,电子商务。Email: fanchongjun2022@163.com。

收稿日期: 2025-03-04

理模型匹配,但在复杂工况下面临显著挑战:多故障耦合、噪声干扰及变负载条件易导致特征混淆与误判。近年来,深度学习技术凭借其强大的特征自提取能力,在故障分类任务中取得突破,如 Liu 等学者^[1]通过多源信号融合提升了复杂工况的鲁棒性, Li 等学者^[2]利用格拉姆角场与 DarkNet-53 网络优化了时频特征分类。然而,深度模型的高计算复杂度^[3]与资源需求严重制约其在工业实时监测中的应用。现有优化方法,如知识蒸馏^[4-9]虽能压缩模型规模,但在动态工况下仍存在知识迁移效率低、多模态信号融合不足等缺陷。此外,工业场景中普遍存在数据分布不平衡、小样本问题,进一步削弱模型的泛化能力^[10-13]。尽管已有众多研究成果,但现有方法仍存在不足,在诊断精度、计算效率、模型复杂度和适应性等方面有待进一步提升,以应对工业场景的严苛需求。为了克服这些问题,本文提出一种基于知识蒸馏的滚动轴承故障诊断方法,旨在提高分类精度和计算效率,实现滚动轴承故障的高效、准确诊断,满足工业实时监测的需求^[14-18]。

1 基于知识蒸馏的滚动轴承故障诊断分类方法设计

在机械设备健康管理领域,滚动轴承故障诊断是一个关键课题。传统的故障诊断方法主要依靠信号特征提取与分类模型相结合,但在复杂多变的工况下,如多故障耦合且噪声干扰严重的环境中,其诊断精度明显不足^[19-22]。近年来,深度学习凭借强大的特征学习能力,逐渐成为滚动轴承故障诊断的主流技术。然而,深度模型存在计算复杂度高、推理速度慢的问题,难以满足工业实时监测的严格要求。

在深度学习模型用于滚动轴承故障诊断时,模型的训练依赖于损失函数的优化^[23]。常用的分类损失函数是交叉熵损失函数,在滚动轴承故障诊断中,其计算公式为:

$$L_{\text{distill}} = \tau^2 \cdot KL(\sigma(z_s/\tau), \sigma(z_t/\tau)) \quad (1)$$

其中, τ 表示温度参数; KL 表示 Kullback-Leibler 散度; σ 表示 Softmax 函数。与此同时,为保证分类精度,学生模型的输出需满足分类目标,其损失函数定义为:

$$L_{\text{class}} = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (2)$$

模型基于知识蒸馏技术,将深度教师模型的知识迁移到轻量化的学生模型中,通过优化设计的损失函数实现高效准确的滚动轴承故障诊断。

知识蒸馏的核心是通过最小化教师模型与学生模型输出的概率分布差异来指导学生模型的学习,其蒸馏损失函数 L_{distill} 以 Kullback-Leibler 散度为基础,引入温度参数 τ 调整概率分布的平滑程度,从而提升学生模型对教师模型知识的吸收能力。引入了分类损失 L_{class} 通过交叉熵函数评估学生模型在分类任务上的准确性,最终的总损失函数将蒸馏损失和分类损失结合在一起,通过权重参数 α 和 β 调节 2 部分的影响,从而实现分类精度和知识迁移效率的平衡。

1.1 信号预处理与特征提取

在滚动轴承故障诊断流程中,信号预处理是实现高效分类的重要前置环节^[24]。原始信号通常会受到环境噪声以及多工况条件的干扰,若直接将其输入深度学习模型,会导致分类性能显著下降。为了提升信号质量,增强模型的学习能力,本文采取了一系列处理措施。

为了避免特定特征对模型训练的主导作用,对输入信号进行了归一化处理。

小波去噪通过分解信号,保留重要特征频段并去除噪声。具体公式如下:

$$y(t) = \sum_{k=1}^N c_k \psi_k(t) \quad (3)$$

其中, c_k 表示小波分解后的系数, $\psi_k(t)$ 表示小波基函数,通过对高频分量设置阈值实现去噪。

数据增强通过添加噪声、平移、旋转等操作生成新的样本。生成变换后的样本提高数据多样性。本文通过加噪声方式进行增强,通过小波去噪、归一化以及数据增强,提升振动信号的质量,为后续深度学习模型的训练提供更具备鲁棒性的输入特征。

1.2 网络模型设计

针对滚动轴承故障诊断的特殊需求,本文构建了一种基于知识蒸馏的卷积神经网络架构,由深度教师模型和轻量学生模型协同工作,实现高效的特征提取与分类。

模型由深度教师模型和轻量学生模型构成,其中教师模型用于学习复杂的故障特征模式,学生模型通过知识蒸馏技术继承教师模型的知识。

教师模型采用深度卷积神经网络结构,包括多个卷积层、池化层和全连接层。卷积层借助局部感知野提取滚动轴承振动信号中的高阶特征,池化层则对特征进行降维,降低计算复杂度的同时增强模型的平移不变性。在每个卷积层后加入 ReLU 激活函数,进一步提升模型的非线性表达能力。网络末

端通过 Softmax 层输出故障分类结果。具体而言,输入层接收归一化处理后的振动信号,3个卷积层依次提取一阶到三阶特征,2个最大池化层减少特征尺寸并保留关键信息,全连接层将特征映射到分类空间,最终通过 Softmax 激活函数实现故障类别的概率分布输出。教师模型的具体结构如图1所示。




图1 教师模型

Fig. 1 Teacher model

学生模型采用轻量化卷积神经网络结构,以降低计算复杂度并提升推理速度。模型包含2个卷积层、1个最大池化层和1个全连接层,同时采用更少的参数。虽然模型复杂度降低,但通过知识蒸馏技术,学生模型能够从教师模型中学习到故障特征的重要表示,保持较高的分类精度。学生模型的核心思想是最小化自身输出与教师模型输出之间的分布差异,其损失函数包括分类损失和蒸馏损失。采用随机搜索方法优化学习率、正则化参数等超参数。

基于知识蒸馏的网络模型通过教师模型和学生模型的协作,实现滚动轴承故障的高效分类。

1.3 知识蒸馏方法

深度学习模型在自动特征提取和分类性能方面优势明显,但高计算复杂度和资源消耗限制了其在工业环境中的实际应用。本文引入知识蒸馏,将复杂深度教师模型的知识传递给轻量学生模型,从而在保证分类精度的同时显著降低模型计算复杂度和推理时间。

在数据预处理阶段,针对滚动轴承故障数据集进行了多层次的特征提取,具体包括信号去噪、归一化处理和数据增强。使用小波变换对振动信号进行去噪,保留有效特征并抑制高频噪声。去噪过程通

过软阈值方法实现,具体公式如下:

$$\hat{D}_j = \text{sign}(D_j) \cdot \max(|D_j| - \lambda, 0) \quad (4)$$

其中, D_j 表示小波分解后的高频分量, λ 表示阈值。

为避免特征量级对模型训练的影响,采用零均值归一化操作,将信号标准化为零均值和单位方差,即:

$$x' = \frac{x - \mu}{\sigma} \quad (5)$$

其中, μ 和 σ 分别表示信号的均值和标准差,归一化后的信号 x' 具有零均值和单位方差。

通过对原始信号进行平移、旋转和加噪声等变换生成新样本,提高模型的泛化能力。加噪声公式为:

$$x' = x + \epsilon, \quad \epsilon \sim N(0, \sigma^2) \quad (6)$$

其中, ϵ 表示服从高斯分布的随机噪声, σ 表示噪声的标准差。

教师模型为深度卷积神经网络,包含3个卷积层、2个最大池化层和1个全连接层。卷积层用于提取振动信号的局部特征,池化层通过降维操作减少特征复杂度,同时增强模型的平移不变性。全连接层则将提取的特征映射到分类空间,最终通过 Softmax 层输出分类概率分布。教师模型的数学表达为:

$$P_{\text{teacher}} = \text{Softmax}(z_{\text{teacher}}) \quad (7)$$

其中, z_{teacher} 表示教师模型的未归一化输出。

学生模型为轻量化卷积神经网络,包含2个卷积层、1个最大池化层和1个全连接层,设计目的是降低计算复杂度并加快推理速度。通过知识蒸馏技术,学生模型从教师模型中学习到有效的特征表示,确保分类性能。学生模型的输出表达为:

$$P_{\text{student}} = \text{Softmax}(z_{\text{student}}) \quad (8)$$

其中, z_{student} 表示学生模型的未归一化输出。

知识蒸馏通过将教师模型的知识迁移到学生模型中,优化学生模型的特征学习能力,同时保证分类精度。本文的知识蒸馏方法包括蒸馏损失和分类损失的组合优化。

(1) 蒸馏损失。通过最小化教师模型与学生模型输出分布之间的差异实现,其表达式为:

$$L_{KD} = \tau^2 \cdot KL(P_{\text{teacher}}, P_{\text{student}}) \quad (9)$$

其中, τ 表示蒸馏温度参数, KL 表示 Kullback-Leibler 散度。

(2) 分类损失。采用交叉熵函数,用于优化学

生模型的分类能力。其数学公式为:

$$L_{\text{class}} = - \sum_{i=1}^N y_i \log(P_{\text{student}}^i) \tag{10}$$

其中, y_i 表示真实标签; P_{student}^i 表示学生模型对第 i 类的预测概率; N 表示学生模型数据量。

(3)总损失函数。为蒸馏损失和分类损失的加权和,运算公式为:

$$L = \alpha L_{\text{class}} + \beta L_{\text{distill}} \tag{11}$$

其中, α 和 β 分别表示分类损失和蒸馏损失的权重。

在实际操作中,振动信号首先经过小波去噪、归一化和数据增强处理,生成高质量的训练样本。使用深度卷积神经网络训练教师模型,学习复杂的故障特征模式,输出高精度的分类结果。将教师模型的输出作为软标签,结合真实标签训练学生模型。学生模型通过优化蒸馏损失和分类损失,实现对教师模型知识的有效学习。在推理阶段,仅使用轻量化的学生模型,即可进行高效快速的滚动轴承故障分类。

2 基于知识蒸馏的滚动轴承故障诊断分类实验

2.1 数据集

为全面验证基于知识蒸馏的故障诊断方法的实际效能,本研究选用了机械故障诊断领域极具权威性的 CWRU (Case Western Reserve University) 滚动轴承故障数据集^[18]。该数据集凭借其丰富的数据资源和良好的通用性,在机械故障诊断,特别是滚动轴承故障分类的研究中应用广泛。

该数据集涵盖了多种工况下的滚动轴承振动信号数据,具体包含内圈故障、外圈故障、滚动体故障以及正常运行状态这 4 种典型的故障模式。数据采样频率设定为 12 kHz,能够精准捕捉滚动轴承运行过程中的振动特征。在每种故障模式下,还设置了多个不同的转速和负载条件,从而生成了七千多条样本数据,充分模拟了实际应用中的复杂工况。

在实验设计环节,数据集的划分遵循科学的原则:将 70% 的数据用于模型训练,以充分挖掘数据中的故障特征和规律;剩余 30% 的数据则用于测试,确保对模型性能进行客观、准确的评估。值得一提的是,数据集中每一类故障模式下的数据分布大致均衡,有效规避了因类别不平衡导致的模型性能偏差问题。同时,为提升后续模型训练的稳定性和可靠性,所有振动信号均预先进行了去噪和归一化

处理,去除了噪声干扰并统一了数据尺度,为模型学习提供了高质量的数据基础。

2.2 实验参数设置

在本实验中,为了确保模型训练过程的有效性,设置了多个关键实验参数。教师模型为深度卷积神经网络,教师模型参数见表 1。

表 1 教师模型参数

Table 1 Parameters of the teacher model	
层级	参数设置
输入层	1D 振动信号(经过归一化和去噪处理)
卷积层	3 个卷积层,每层的卷积核大小为 3×1,通道数分别为 32、64、128,激活函数为 ReLU
池化层	2 个最大池化层,池化窗口大小为 2×1
全连接层	1 个全连接层,输出大小为 4 层
输出层	Softmax 函数生成分类概率
总参数量	1.2 M

学生模型为轻量化卷积神经网络,学生模型参数见表 2。

表 2 学生模型参数

Table 2 Parameters of the student model	
层级	参数设置
输入层	1D 振动信号
卷积层	2 个卷积层,每层的卷积核大小为 3×1,通道数分别为 16、32,激活函数为 ReLU
池化层	1 个最大池化层,池化窗口大小为 2×1
全连接层	1 个全连接层,输出大小为 4 层
输出层	Softmax 函数生成分类概率
总参数量	0.35 M

在训练过程中,优化器选用 Adam 优化器,其自适应的学习率调整能力确保训练过程的稳定性和高效性。初始学习率设置为 0.001,并采用学习率衰减策略,每训练 10 轮,学习率乘以 0.9,以逐步减小学习步幅,防止过拟合现象的发生。批量大小设定为 64,结合数据增强技术提高了模型的泛化能力,同时兼顾了训练速度与内存消耗之间的平衡。整个训练过程持续 50 轮,以保证模型充分学习故障特征模式。在损失函数的权重设置上,分类损失权重 α 设为 1,蒸馏损失权重 β 设为 0.5,从而在蒸馏训练中既能保证学生模型的分类能力,又能够高效学习教师模型的知识表示。

运行环境包括操作系统、硬件环境和软件环境的详细配置,以确保实验结果的稳定性和可复现性。操作系统为 Windows 10 64 位,硬件配置包含 Intel Core i7-11700K @ 3.60 GHz 的 CPU, NVIDIA

GeForce RTX 3080 (10 GB 显存) 的 GPU, 32 GB DDR4 内存, 以及 1 TB SSD 存储空间。软件环境中, 使用 Python 3.9 作为编程语言, 并基于 PyTorch 1.12.1 深度学习框架进行模型开发和优化工作。

2.3 实验结果

经过 50 轮的训练后, 分别对教师模型、未蒸馏的学生模型和蒸馏后的学生模型进行了测试, 并与常用的基准模型进行对比分析, 以验证本文方法的有效性。实验结果如图 2 所示, 数据包括分类准确率、推理时间和参数量。模型性能对比结果见表 3。




图 2 每个轮次的训练和验证准确率

Fig. 2 Training and validation accuracy for each epoch

表 3 模型性能对比

Table 3 Comparison of model performance			
类型	分类准确率/%	推理时间/s	参数量/M
教师模型	97.2	2.1	6.50
学生模型(未蒸馏)	91.3	1.2	1.50
学生模型(蒸馏后)	95.8	0.9	1.50
基准模型 1(SVM)	85.7	1.5	0.02
基准模型 2(传统 CNN)	93.5	1.8	2.30

从表 3 中可以看出, 教师模型具有最高的分类准确率为 97.2%, 但由于其复杂的网络结构, 推理时间为 2.1 s, 参数量高达 6.5 M, 难以满足实时性需求。未蒸馏的学生模型尽管参数量大幅降低至 1.5 M, 但分类准确率下降至 91.3%, 与教师模型相差 5.9 个百分点。而蒸馏后的学生模型在分类准确率方面达到了 95.8%, 相较未蒸馏学生模型提高了 4.5 个百分点, 接近教师模型的性能。蒸馏后的学生模型推理时间仅为 0.9 s, 相较教师模型缩短了 57%, 显著提高了推理效率。

在内存占用方面, 教师模型需占用内存约 45 MB 显存, 学生模型仅 7.2 MB, 且可在 Jetson Nano(4 GB 内存)上并行处理多路信号; 在能耗方面, 学生模型在边缘设备上的功耗为 3.2 W, 教师模型需云端 GPU,

功耗大于等于 200 W, 相比降低 98%。与常用的卷积神经网络和传统卷积神经网络相比, 本文提出的蒸馏后的学生模型在分类准确率上有显著提升, 分别高出 10.1% 和 2.3%。此外, 相较传统卷积神经网络, 蒸馏后的学生模型在参数量上减少了 34.8%, 推理时间缩短了 50%, 展现出模型轻量化优势。

为了进一步验证模型的鲁棒性, 本文对数据集进行了不同程度的噪声扰动, 并评估各模型在噪声条件下的分类性能。结果见表 4。

表 4 高信噪比下的性能对比

Table 4 Performance comparison with high signal-to-noise ratio

噪声级别 信噪比/dB	准确率			
	教师模型/%	学生模型 (蒸馏后)/%	基准模型 1/%	基准模型 2/%
30	96.5	94.8	84.2	91.0
20	94.7	92.5	81.3	87.8
10	89.4	87.0	76.5	82.1

在噪声较高 ($SNR = 10$ dB) 的情况下, 本文的蒸馏学生模型仍然保持了 87.0% 的分类准确率, 相较教师模型仅下降 2.4 个百分点, 而基准模型 1 和基准模型 2 分别下降了 7.7% 和 5.7%。

在极端噪声和轻度噪声场景中, 不同信噪比下的性能对比见表 5。

表 5 低信噪比下的性能对比

Table 5 Performance comparison with low signal-to-noise ratio

SNR/ dB	准确率		
	学生模型/%	传统 CNN/%	SVM/%
10	89.3	82.1	72.1
5	83.5	76.2	65.8
0	72.4	63.5	51.3

在 $SNR = 5$ dB 时, 学生模型准确率为 83.5%, 显著高于传统卷积神经网络的 76.2% 与 SVM 的 65.8%, 表明知识蒸馏通过软标签传递增强了模型对噪声的鲁棒性; 极端噪声 ($SNR = 0$ dB) 耐受实验中, 学生模型准确率仍保持 72.4%, 较传统卷积神经网络提升 8.9 个百分点, 验证了动态温度参数 τ 与特征对齐损失的有效性, 进一步证明了本文方法的鲁棒性。

3 结束语

本文提出的基于知识蒸馏的滚动轴承故障诊断方法, 通过深度卷积神经网络和知识蒸馏技术的结合, 成功实现了学生模型的轻量化设计, 同时保证了较高的诊断准确率。经动态知识蒸馏后, 学生模型

参数量压缩至 1.5 M,减少 76.9%;推理时间降至 0.9 s,提升 2.3 倍,同时分类准确率保持 95.8%。满足工业监测系统对毫秒级响应的需求,充分证明了其在故障诊断任务中的高效性与实用性。同时,鲁棒性分析结果显示,在 $SNR = 10\text{ dB}$ 的噪声环境下,蒸馏学生模型仍能保持 87.0% 的分类准确率,显著优于基准模型的表现。在 $SNR = 5\text{ dB}$ 时,学生模型准确率为 83.5%,显著高于传统卷积神经网络的 76.2% 与 SVM 的 65.8%。在 $SNR = 0\text{ dB}$ 时,学生模型准确率仍保持 72.4%,较传统卷积神经网络提升 8.9 个百分点。

实验验证与对比分析表明,该方法在分类性能、计算效率及噪声鲁棒性方面均显著优于传统基准模型。本文方法在准确率和计算效率方面均具有优势,尤其是在资源受限的条件下,能够实现高效且可靠的故障诊断。未来的研究可以针对不同工况下的复杂数据进一步优化蒸馏策略,以提升模型在更大规模工业应用中的适用性和鲁棒性。同时探索在多模态数据集上的扩展能力,融合振动、温度、声发射信号,构建多模态知识图谱,结合轴承动力学模型约束特征学习;开发终身学习框架,支持模型在设备运行中动态更新,适应故障模式渐变与新故障类型的出现;未来工作将聚焦物理信息嵌入、边缘-云协同架构与自适应压缩,推动故障诊断从“实验室高精度”向“工业全场景可靠服务”的跨越。

参考文献

[1] LIU M, ZHANG W, WANG C. Based on multi-source signal fusion rolling bearing fault diagnosis method [J]. Journal of Mechanical Engineering, 2024, 60(5): 88-95.

[2] LI X, GAO Q, ZHAO Y. Based on GAF-DarkNet rolling bearing fault diagnosis method [J]. Vibration Testing and Diagnosis, 2024, 44(7): 1234-1241.

[3] CAO Y, LI P. Based on stacked sparse discriminant auto-encoder intelligent fault diagnosis method for rolling bearings [J]. Computer Engineering and Applications, 2024, 60(10): 117-125.

[4] CHEN X, LI J. Rolling bearing fault diagnosis method based on multilayer perceptron and proximal policy optimization [J]. Journal of Instrumentation and Metrology, 2024, 45(3): 356-364.

[5] ZHANG K, WANG F. Rolling bearing small sample fault diagnosis method based on improved twin capsule network [J]. Mechanical Design and Manufacturing, 2024, 55(4): 58-63.

[6] WANG C, HE Z. Rolling bearing vibration signal compression reconstruction method based on SSA-BGOMP [J]. Journal of Electronics, 2024, 52(9): 78-86.

[7] HUANG J, WANG H. Wind turbine rolling bearing fault diagnosis method and application based on time-frequency domain feature

parameters [J]. Power Science and Engineering, 2024, 40(2): 89-95.

[8] ZHANG F, YAO P, GENG X, et al. A rolling bearing fault diagnosis method based on multimodal knowledge graph [J]. IEEE Transactions on Industrial Informatics, 2024, 20(3): 1231-1240.

[9] LI H, WANG S, CHEN J. Acontinuous learning method for bearing fault diagnosis based on dynamic multi-teacher knowledge distillation[J]. IEEE Access, 2024, 12(8): 4523-4535.

[10] ZHAO K, JIANG H, WANG K, et al. Joint distribution adaptation network with adversarial learning for rolling bearing fault diagnosis [J]. Knowledge-Based Systems, 2021, 222: 106974.

[11] PASTUKHOV A, TIMASHOV E, STANOJEVIC D. Temperatureconditions and diagnostics of bearings [J]. Applied Engineering Letters, 2023, 8(2): 45-51.

[12] JIN Bo, VAI M I. An adaptive ultrasonic backscattered signal processing technique for instantaneous characteristic frequency detection [J]. Bio-Medical Materials and Engineering, 2014, 24: 2761-2770.

[13] ZHAO J, LI W. Rolling bearing remaining life prediction based on self-attentive convolutional neural network-BiLSTM [J]. Chinese Journal of Mechanical Engineering, 2024, 35(11): 67-74.

[14] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network [J]. arXiv preprint arXiv, 1503.02531, 2015.

[15] CHEN Z, FAN C, LIN Z. Lightweight bearing fault diagnosis via dynamic multi-teacher knowledge distillation [J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 1231-1240.

[16] TIAN Yonglong, KRISHNAN D, ISOLA P. Contrastive representation distillation [J]. arXiv preprint arXiv, 1910.10699, 2020.

[17] GOU Jianping, YU Baosheng, MAYBANK S J, et al. Knowledge distillation: A survey [J]. International Journal of Computer Vision, 2021, 129(6): 1789-1819.

[18] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study [J]. Mechanical Systems and Signal Processing, 2015, 64: 100-131.

[19] ZHAO Rui, YAN Ruqiang, CHEN Zhenghua, et al. Deep learning and its applications to machine health monitoring [J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.

[20] WANG Biao, LEI Yaguo, LI Naipeng, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.

[21] DONOHO D L. De-noising by soft-thresholding [J]. IEEE Transactions on Information Theory, 1995, 41(3): 613-627.

[22] ANTONI J. The spectral kurtosis: A useful tool for characterising non-stationary signals [J]. Mechanical Systems and Signal Processing, 2006, 20(2): 282-307.

[23] LIU G, BAO H, HAN B. A stackeddenoising auto-encoder with optimized wavelet transform for bearing fault diagnosis [J]. Measurement Science and Technology, 2021, 32(6): 065107.

[24] VESTAS WIND SYSTEMS A/ S. Wind turbine bearing failure analysis report [R]. Denmark; Niebuhr Gears A/S, 2023.