# 基于不变风险最小化的未知工况轴承故障诊断

# 马骥腾,吕卫民<sup>\*</sup>,李根,戴梓琴

(海军航空大学,山东烟台264001)

摘要:目的 实现在未知工况下能够稳定识别轴承故障类型的智能故障诊断。方法 针对传统智能故障诊断 方法模型泛化能力弱、领域适应等迁移学习方法数据依赖性强的问题,提出一种基于不变风险最小化的未 知工况轴承故障诊断方法。利用多个可用工况的振动信号数据,经过数据增强技术进行预处理,并采用不 变风险最小化策略来约束特征提取器和领域分类器,使其能够学习到在未知工况中不变的特征和知识。该 方法能够有效提升模型在未知工况下的泛化能力,减少对特定工况数据的依赖。结果 实验证明,该方法在 多个未知工况的诊断任务上实现了令人满意的诊断精度和鲁棒性。结论 在面对工况信息未知但故障特征相 关的情况时,无需未知工况的对应数据,该方法使得深度模型可以更好地泛化并实现高精度轴承故障诊断。 关键词:不变风险最小化;轴承;故障诊断;振动信号;深度学习;迁移学习 中图分类号:TH165.3 文献标志码:A 文章编号:1672-9242(2024)10-0094-07 DOI: 10.7643/issn.1672-9242.2024.10.012

## Bearings Fault Diagnosis under Variable Operating Conditions Based on Invariant Risk Minimization

*MA Jiteng*, *LYU Weimin*<sup>\*</sup>, *LI Gen*, *DAI Ziqin* (Naval Aviation University, Shandong Yantai, 264001, China)

**ABSTRACT:** The work aims to achieve intelligent fault diagnosis that can stably identify bearing fault types under unknown working conditions. To address the problems of weak model generalization ability in traditional intelligent fault diagnosis methods and the strong data dependency of transfer learning methods such as domain adaptation, an unknown working condition bearing fault diagnosis method based on invariant risk minimization was proposed. The vibration signal data from multiple available working conditions were preprocessed through data augmentation techniques. The invariant risk minimization strategy was adopted to constrain the feature extractor and domain classifier, enabling them to learn features and knowledge that remain invariant across unknown working conditions. This method could effectively improve the generalization ability of the model under unknown working conditions and reduce the reliance on specific working condition data. Experiments demonstrated that this method achieved satisfactory diagnostic accuracy and robustness in diagnostic tasks under multiple unknown working conditions. In conclusion, when facing situations where the working condition information is unknown but fault characteristics are related, this method allows deep models to generalize better and achieve high-precision bearing fault diagnosis without requiring corresponding data from unknown working conditions.

KEY WORDS: invariant risk minimization; bearings; fault diagnosis; vibration signal; deep learning; transfer learning

MA Jiteng, LYU Weimin, LI Gen, et al. Bearings Fault Diagnosis under Variable Operating Conditions Based on Invariant Risk Minimization[J]. Equipment Environmental Engineering, 2024, 21(10): 94-100.

收稿日期: 2024-06-21; 修订日期: 2024-08-13

Received: 2024-06-21; Revised: 2024-08-13

引文格式:马骥腾,吕卫民,李根,等.基于不变风险最小化的未知工况轴承故障诊断[J].装备环境工程,2024,21(10):94-100.

<sup>\*</sup>通信作者(Corresponding author)

轴承作为减少摩擦、确保机械设备平稳运行的关键精密零部件,广泛应用于航空、航天、船舶、汽车等诸多领域的旋转机械设备中<sup>[1-3]</sup>。与旋转机械的其他零部件相比,轴承常常在高温、高转速、大负载等恶劣环境条件下工作,且内部易受到碰撞摩擦、离心力和热变形等因素的影响,故障发生率较高,且维护难度大。轴承对于机械装备的安全运行至关重要,严重故障时甚至造成人员伤亡。由于缺乏有效的监测和诊断技术,许多在变工况下运行的轴承在未达到使用寿命前就被定期检修更换,导致机械设备运行中产生时间和经济上的双重负担<sup>[4]</sup>。因此,研究变工况下的轴承故障诊断技术势在必行,这是我国装备制造业的迫切需求,也是确保机械设备可靠性的关键保障。

随着人工智能技术和传感器技术的飞速发展,故 障诊断的研究方法逐步从传统的人工提取特征的机 器学习方法,转向目前可以自动提取大数据特征的深 度学习方法<sup>[5-9]</sup>。基于深度学习的故障诊断方法可以 构建振动信号到故障类型之间的映射,利用卷积神经 网络、循环神经网络、自动编码器等典型网络结构, 实现轴承端到端的故障诊断。然而,仍有 2 个主要问 题需要解决:一是数据分布差异性<sup>[10]</sup>,深度学习模型 假设训练样本和测试样本属于独立同分布,但在实际 工程应用中,轴承在不同负载、转速等变工况条件下 的数据分布往往不同<sup>[11]</sup>;二是数据可用性<sup>[12]</sup>,收集 和标记大量故障数据十分困难,部分故障轴承在机器 中的持续运行会增加运行风险,故障严重时甚至无法 收集到有效数据<sup>[13]</sup>。

针对分布差异性问题,目前的解决思路是利用源 域与目标域数据进行域适应,放宽训练和测试数据必 须遵循相同分布的限制。王健等[14]提出了结合域对抗 神经网络与宽卷积核卷积神经网络的新诊断模型,并 通过对目标域带标签数据进行训练进行变工况轴承 故障诊断。田静等[15]提出了一种基于对抗学习和指数 调节策略的域适应方法,使得深度诊断模型更有针对 性地适应目标域的数据分布。王玉静等[16]提出了一种 基于进化策略的与模型无关的元学习改进异构模型 参数迁移策略,将源域知识迁移到多个目标域后,再 将其提取的特征融合到同一个极限学习机中,实现 多源域异构模型的轴承故障诊断。目前,现有的未 知工况轴承故障诊断研究主要解决分布差异性问 题,但考虑数据可用性的变工况轴承故障诊断研究 较少,而且在没有目标域数据的情况下,领域适应 的方法将失效。

针对以上问题,本文提出了一种基于不变风险最 小化的未知工况轴承故障诊断方法。该方法可以避免 目标域数据不可用的问题,其核心在于利用多个已知 工况的振动信号数据,经过数据增强技术进行预处 理,并采用不变风险最小化策略来约束特征提取器和 故障分类器,使其能够学习到在未知工况中不变的特 征。区别于特定数据分布对齐的领域适应思想,该方 法侧重于不同工况下故障特征不变的领域泛化思想。 实验表明,基于不变风险最小化的故障诊断方法在未 知工况下的轴承故障诊断任务上取得了很高的精度, 能够有效提升模型在未知工况下的泛化能力,减少对 特定工况数据的依赖,具有较高的工程应用价值。

## 1 经验风险最小化与不变风险最小化

经验风险最小化(Empirical Risk Minimization, ERM)是机器学习理论中常见的有关模型性能理论界 限的准则<sup>[17]</sup>,即经验风险最小的模型就是最优模型。 极大似然估计就是其中一个很好的例子,当样本容量 足够大、模型是条件概率分布且损失函数是对数损失 函数时,经验风险最小化等于极大似然估计。但经验 风险最小化采用随机梯度下降算法优化时,受数据选 择偏差、混杂因素和其他特性的影响,存在过拟合的 风险。

为了使模型在训练数据之外的未知数据上也能 良好泛化,需要减少数据及其标签之间的虚假相关 性,以减轻机器学习模型对数据偏差的过度依赖。对 比经验风险最小化,不变风险最小化(Invariant Risk Minimization, IRM)<sup>[18]</sup>作为一种新的准则可以估计 来自多个不同、独立的环境的非线性、不变的稳定特 征,以实现跨环境的数据及其标签之间相关性不变。 此时,对稳定特征有2个优化目标:一是在该稳定特 征之上存在最优分类器,即风险最小;二是该稳定特 征在不同环境中依然有效。数学上,这2个优化目标 可以写为约束优化形式:

$$\min_{\omega, \Phi} = \sum_{e \in E} \mathcal{R}^{e}(\omega, \Phi)$$
(1)

 $s.t.\omega \in \arg\min_{\omega^e} \mathcal{R}^e(\omega^e, \Phi)$ 

式中:  $\omega$  表示分类器;  $\Phi$  表示特征提取器;  $E = \{e_1, e_2, ..., e_E\}$  表示多个不同环境;  $\mathcal{R}$  表示风险,也称损失。该式可以解释为要学习跨环境的不变性,需要寻找一个合适的特征提取器,使得分类器匹配所有环境下提取的稳定特征,并实现最佳性能。

上述优化形式中的硬约束可以转化为适应深度 学习的损失函数惩罚项,

$$\mathcal{L}_{\mathrm{IRM}}(\omega, \Phi) = \sum_{e \in E} \mathcal{R}^{e}(\omega, \Phi) + \lambda \cdot \mathbb{D}(\omega, \Phi, e)$$
(2)

式中:函数 D度量了  $\omega$  与 R<sup>e</sup>( $\omega, \sigma$ ) 之间的接近程度,  $\lambda \in [0, \infty]$  是一个用来平衡分类性能与特征稳定性的超参数。函数 D可以用两个线性最小二乘分类器之间的差异表示:

$$\mathbb{D}_{\text{dist}}(\omega, \Phi, e) = \left\| \omega - \omega_{\Phi}^{e} \right\|^{2}$$
(3)

这种形式在函数空间内非凸,不易收敛到最优。 而另一种思路是,如果分类器在每个环境下都最优,

(6)

$$\mathbb{D}_{\text{IRM}}(\omega, \Phi, e) = \left\| \nabla_{\omega} \mathcal{R}^{e}(\omega, \Phi) \right\|^{2}$$
(4)

最终在实际训练中,使用不变风险最小化的损失 函数为:

$$\mathcal{L}_{\text{IRM}}(\omega, \Phi) = \sum_{e \in E} \mathcal{R}^{e}(\omega, \Phi) + \lambda \cdot \left\| \nabla_{\omega} \mathcal{R}^{e}(\omega, \Phi) \right\|^{2}$$
(5)

# 2 基于不变风险最小化的故障诊断 方法

第1节的理论表明,当测试数据分布与训练数据 分布产生差异时,单纯依赖经验风险最小化优化的模 型难以满足要求。而依赖领域适应的迁移学习方法只 能处理源域数据到目标域数据的定向迁移,且训练阶 段仍需要目标域数据<sup>[19-21]</sup>。在实际工业应用中,轴承 运行的工况是连续变化的,进而直接导致了数据分布 的连续变化。基于经验风险最小化训练的模型要识别 到各种工况下的轴承健康状态势必需要全面收集到 各种工况下的含标签样本,但这种数据采集方案无论 是时间还是经济上都是不可能的。因此,需要一种方 法可以将部分工况下的含标签样本训练的诊断模型 泛化到未知的工况下,以有效地完成一个未知工况轴 承故障诊断任务。为此,本文从输入数据增强技术、 模型残差结构和不变风险最小化 3 个方面建立变工 况的轴承故障诊断方法。

首先是输入数据增强技术。在智能故障诊断中, 一般训练样本越多,模型的泛化性能就越好,所以在 模型输入层利用数据增强技术将数据通过时间平移、 添加噪声、随机缩放、数据截断等方式扩充其多样性。 时间平移是指在振动信号上沿时间轴平移一个固定 的时间间隔。对于输入数据 x 来说,噪声添加是随机 将高斯噪声添加到输入信号,记为:

x = x + n

其中 *n* 是由高斯分布 *N*(0,0.01) 中采样获取的。 随机缩放是将振动信号与随机因子相乘,记为:

 $x = \beta * x \tag{7}$ 

其中 β 是遵循高斯分布 N(1,0.01) 的缩放器。数 据截断是指的是利用二进制掩码随机覆盖部分信号, 记为:

 $x = \max k * x \tag{8}$ 

其中 mask 是任意位置子序列为零的二进制序 列,一般子序列长度取为 10。经过输入数据增强后, 扩大了数据集的规模,提升了诊断模型的泛化能力。

其次是模型残差结构。在智能故障诊断中,使用 最广的就是卷积神经网络,卷积神经网络以卷积块形 式分层提取从低级简单特征到高级复杂特征。当网络 深度进一步增加时,继续简单堆叠卷积层的效果反而 变差,可能出现性能退化的问题。原因是反向传播很 难把后面层的梯度更新到前面层,网络的残差结构通 过跨层连接有效将深层网络的梯度向前传递。除跨层 连接外,还增加批次归一化层统计特征的均值、方差 并将其标准化处理,解析表达式为:

$$\mu_{\rm BN} = \frac{1}{m} \sum_{i=1}^{m} x_i \tag{9}$$

$$\sigma_{\rm BN}^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_{\rm BN})^2$$
(10)

$$\hat{x}_i = \frac{x_i - \mu_{\rm BN}}{\sqrt{\sigma_{\rm BN}^2 + \varepsilon}} \tag{11}$$

式中:  $x_i$ 代表一个批次中的任意中间特征, 批次 大小为 m;  $\mu_{BN}$ 代表这个批次的均值;  $\sigma_{BN}^2$ 代表这个 批次的方差;  $\varepsilon$ 是一微小值(例如 1×10<sup>-7</sup>), 避免分 母为零;  $\hat{x}_i$ 代表经过批次归一化层后输出的特征。模 型残差结构有助于训练更深的网络, 提取到更丰富的 故障特征, 从而提升诊断性能。本文所用的具有残差 结构卷积故障诊断模型具体参数见表 1。

最后是不变风险最小化,也是诊断模型可以跨工 况稳定诊断故障的关键。为了将不变风险最小化嵌入 到卷积神经网络中进行训练,式(5)中的风险可以 利用交叉熵进行计算,记为:

$$\mathbf{R}(\omega, \boldsymbol{\Phi}, \boldsymbol{x}, \boldsymbol{y}) = -\frac{1}{N} \sum_{i=1}^{N} y_i \log\left\{\omega[\boldsymbol{\Phi}(\boldsymbol{x}_i)]\right\}$$
(12)

其中, x,y分别表示输入振动信号及故障标签。 最后在多个已知环境数据中利用随机梯度下降 (Stochastic Gradient Descent, SGD)<sup>[22]</sup>优化整体的 模型参数。经过不变风险最小化策略训练后,约束了 特征提取器和故障分类器,使得不变风险最小化对比 经验风险最小化能够学习到在未知工况信号中不变 的特征和知识。另外,因为模型是从不同的数据环境 中学习的,更有可能泛化到新的分布外数据上。

基于不变风险最小化的故障诊断方法流程如图1 所示。首先,使用振动传感器在多种已知工况下采集 机械设备的运行数据,确保数据采集的频率和精度足 够高,以捕捉到故障信号。接着,对采集到的原始信 号进行清洗处理,包括去噪、滤波和归一化等操作, 并将时域信号切分成多个已知域的训练数据集。然 后,选择上述具有残差结构的卷积模型作为故障诊断 模型,并基于不变风险最小化进行前向传播和反向更 新,不断迭代优化模型参数,直到达到预设的训练轮 次。经过不变风险最小化处理后,模型学习到的故障 特征在多个工况域中是保持不变的,因此模型具有很 好的泛化性。训练完成的模型将其用于测试未知工况 的轴承振动信号,由于不变风险最小化从理论上保证 了模型的泛化性能,所以能够很好完成未知工况下的 轴承故障诊断任务,并减少对特定工况数据的依赖。

Tab.1 Convolutional fault diagnosis model parameters with residual structure							
网络层	卷积核大小	步长	填充	滤波器数量	激活函数	输出大小	残差结构
输入层	/	/	/	/	/	1×1024	/
卷积层 1	7	2	3	64	ReLU	64×512	/
批次归一化层 1	/	/	/	/	/	64×512	/
最大池化层	3	2	1	/	/	64×256	/
卷积层 2	3	1	1	64	ReLU	64×256	/
卷积层 3	3	1	1	64	/	64×256	有
卷积层 4	3	1	1	64	ReLU	64×256	/
卷积层 5	3	1	1	64	/	64×256	有
批次归一化层 2	/	/	/	/	/	64×256	/
卷积层 6	3	2	1	128	ReLU	128×128	/
卷积层 7	3	1	1	128	/	128×128	有
卷积层 8	3	1	1	128	ReLU	128×128	/
卷积层 9	3	1	1	128	/	128×128	有
批次归一化层 3	/	/	/	/	/	128×128	/
卷积层 10	3	2	1	256	ReLU	256×64	/
卷积层 11	3	1	1	256	/	256×64	有
卷积层 12	3	1	1	256	ReLU	256×64	/
卷积层 13	3	1	1	256	/	256×64	有
批次归一化层 4	/	/	/	/	/	256×64	/
卷积层 14	3	2	1	512	ReLU	512×32	/
卷积层 15	3	1	1	512	/	512×32	有
卷积层 16	3	1	1	512	ReLU	512×32	/
卷积层 17	3	1	1	512	/	512×32	有
批次归一化层 4	/	/	/	/	/	512×32	/
平均池化层	/	/	/	/	/	512×1	/
全连接层	/	/	/	/	/	4×1	/
Softmax 层	/	/	/	/	/	4	/





图 1 基于不变风险最小化的未知工况轴承故障诊断流程 Fig.1 Bearing fault diagnosis process under unknown operating conditions based on invariant risk minimization

#### 3 轴承故障诊断实验

#### 3.1 实验系统配置

本文通过轴承故障诊断实验来验证提出的方法 在未知工况下的轴承故障诊断任务上的有效性。实验 系统采用德国帕德伯恩大学轴承试验台<sup>[23]</sup>,由电机、 扭矩测量轴、轴承测试台、飞轮和负载电机组成,如 图 2 所示。不同故障类型的轴承都会被安装在轴承测 试台,然后收集不同工况下轴承运行的振动信号。故 障轴承型号为 SKF6203,振动信号采样率为 64 kHz。

表2中设置了4种轴承故障诊断实验的不同运行 工况,主要参数是转速、负载和径向力。为了验证基 于不变风险最小化的故障诊断方法在未知工况下的 轴承故障诊断性能,设计了在任意3种运行工况下进 行训练,在最后一种运行工况下进行测试的诊断任 务,具体设计实验任务见表3。每个任务都包含正常、 内圈、外圈、内圈加外圈4种状态,但最终测试的未 知工况有所不同,这样能有助于体现方法的普适性。

#### 3.2 实验结果及分析

为了评估所提方法的最佳性能,需要寻找式(2)



图 2 德国帕德伯恩大学轴承故障试验台<sup>[23]</sup> Fig.2 Bearing failure test bench at University of Paderborn in Germany<sup>[23]</sup>

	表 2 轴承	不同运行	L况设置	
Tab.2 Setting	of bearing u	nder differe	ent operating	conditions
工况名称	转速/(r	·min <sup>-1</sup> ) 负	〔载/(N·m)	径向力/N

		) , , , , , , , , , , , , , , , , , , ,	,
N15_M07_F10	1 500	0.7	1 000
N15_M01_F10	1 500	0.1	1 000
N09_M07_F10	900	0.7	1 000
N15_M07_F04	1 500	0.7	400

中的最优平衡参数 λ, 因为这是影响分类性能与特征 稳定性的关键超参数。以任务 4 为例, 共设定了 12 个平衡参数的取值, 分别是[0, 0.01, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0], 各参数下诊断精度取值如 图 3 所示。从图 3 中可以发现, 在平衡参数为 0.01 时,诊断模型的性能最好, 所以在后续其他未知工况 诊断任务中, 均采用 0.01 作为平衡参数取值。

表 3 不同未知工况下的轴承故障诊断任务设置 Tab 3 Setting of bearing fault diagnosis tasks under different unknown operating conditions

实验任务	训练集已知工况设定	测试集未知工况设定	训练集样本数量	测试集样本数量	轴承状态	
$T_1$	N09_M07_F10 N15_M01_F10 N15_M07_F04	N15_M07_F10	720	240	正常、内圈、外圈、 内圈加外圈	
$T_2$	N15_M07_F10 N09_M07_F10 N15_M07_F04	N15_M01_F10	720	240	正常、内圈、外圈、 内圈加外圈	
T <sub>3</sub>	N15_M07_F10 N15_M01_F10 N15_M07_F04	N09_M07_F10	720	240	正常、内圈、外圈、 内圈加外圈	
$T_4$	N15_M07_F10 N15_M01_F10 N09_M07_F10	N15_M07_F04	720	240	正常、内圈、外圈、 内圈加外圈	



图 3 不同平衡参数下诊断模型性能对比 Fig.3 Comparison of diagnostic model performance under different equilibrium parameters

为进一步证明提出方法的有效性,除经验风险最小化外,选择最大均值差异(MMD)<sup>[24]</sup>、局部最大均值最小二乘差异(JMMD)<sup>[25]</sup>,层激活相关性对齐

(CORAL)<sup>[26]</sup>等 3 种代表性的迁移学习方法进行对 比。与从源域到目标域的领域适应迁移不同,这 3 种 对比方法是对于任意 2 个工况的数据进行分布对齐, 充分利用了现有已知工况的数据。图 4 和表 3 展示了



图 4 不同方法在多个未知工况诊断任务上的诊断精度 Fig.4 Diagnostic accuracy of different methods on diagnosis tasks under multiple unknown operating conditions

表3 不同方法在未知工况诊断任务上的诊断精度对比 Tab.3 Comparison of different methods in fault diagnosis tasks under unknown operating conditions 经验风险 最大均值 局部最大均值最小<sup>一</sup>乘 厚激活相关性 不

实验	经验风险	最大均值	局部最大均值最小二乘	层激活相关性	不变风险
任务	最小化/%	差异/%	差异/%	对齐/%	最小化/%
$T_1$	82.701	86.161	88.058	82.142	98.772
$T_2$	81.473	86.607	87.946	81.361	98.437
T <sub>3</sub>	63.727	63.392	59.041	64.062	83.928
$T_4$	88.616	90.959	85.044	88.951	92.857
平均	79.129	81.781	80.022	79.129	93.498

这 5 种不同方法在未知工况诊断任务上的结果对比, 包含 4 个任务及任务平均。从图 4 可见,基于不变风 险最小化的诊断模型在所有任务上都优于其他方法, 而且在所有任务的平均诊断精度上对比其他方法有 显著的提升。这无疑说明,该方法不仅具有更好的未 知工况泛化性,而且在单个诊断任务上也取得了更好 的效果。

### 4 结语

文中提出了一种基于不变风险最小化的未知工况轴承故障诊断方法,能够实现在未知工况下准确稳 定识别轴承故障类型。此方法优势在于能够使诊断模 型学习到在多种不同工况数据中不变且更好的特征, 从而减少对特定工况数据的依赖。4个未知工况轴承 故障诊断实验证明所提方法不仅具有比其他方法更 好的故障精度,而且从所有诊断任务来看模型具有显 著的未知工况泛化性及通用性。但这种未知工况的泛 化性依赖于收集多个可用工况的差异性,即学习到的 不变特征受到数据来源影响较大。后续研究将集中在 如何降低数据来源对不变特征的影响,主要思路一种 是引入外部轴承参数等知识对神经网络进一步约束, 另一种是利用信号处理等方法赋能神经网络以提取 可解释的不变特征。

#### 参考文献:

- 陈仁祥,陈思杨,杨黎霞,等.基于振动敏感时频特征的航天轴承寿命状态识别方法[J].振动与冲击,2016,35(17):134-139.
   CHEN R X, CHEN S Y, YANG L X, et al. Life State Recognition Method for Space Bearings Based on Sensitive Time-Frequency Features of Vibration[J]. Journal of Vibration and Shock, 2016, 35(17): 134-139.
   沙云东,赵俊豪,栾孝驰,等.基于阈值参数判决筛选
- [2] 秒云示, 应该家, 未孕驰, 寻. 墨了两值多数判获师选 的航空发动机主轴承故障特征提取方法[J/OL]. 航空 动力学报, 2024, 39: 1-13. [2023-09-22]. https://doi.org/ 10.13224/j.cnki.jasp.20230341.

SHA Y D, ZHAO J H, LUAN X C, et al. A method for extracting fault features of aircraft engine main bearings based on threshold parameter judgment screening[J/OL].

Journal of Aerospace Power, 2024, 39: 1-13. [2023-09-22]. https://doi.org/10.13224/j.cnki.jasp.20230341.

 [3] 任燕, 石炳欣. AR 模型在船舶旋转机械故障诊断和状态预测技术的应用[J]. 舰船科学技术, 2022, 44(24): 177-180.
 REN Y, SHI B X. Application of AR Model in Fault Di-

REN Y, SHI B X. Application of AR Model in Fault Diagnosis and Condition Prediction of Ship Rotating Machinery[J]. Ship Science and Technology, 2022, 44(24): 177-180.

- [4] 胡春生,李国利,赵勇,等.变工况滚动轴承故障诊断 方法综述[J]. 计算机工程与应用, 2022, 58(18): 26-42.
  HU C S, LI G L, ZHAO Y, et al. Summary of Fault Diagnosis Methods for Rolling Bearings under Variable Working Conditions[J]. Computer Engineering and Applications, 2022, 58(18): 26-42.
- [5] 张小强,朱文辉,康铁宇,等.基于人工免疫算法的离散隐马尔科夫故障诊断模型优化[J].装备环境工程,2019,16(1):63-67. ZHANG X Q, ZHU W H, KANG T Y, et al. Optimization of Discrete Hidden Markov Fault Diagnosis Model Based on Artificial Immune Algorithm[J]. Equipment Environmental Engineering, 2019, 16(1): 63-67.
- [6] 唐其琯,车驰东.基于决策树支持向量机算法的船用 设备故障诊断[J].装备环境工程,2021,18(9):72-77. TANG Q G, CHE C D. Research on Marine Equipment Fault Diagnosis Based on Decision Tree Support Vector Machine Algorithm[J]. Equipment Environmental Engineering, 2021, 18(9): 72-77.
- [7] 武雅曼, 谌鹏, 张滇, 等. 基于 AVMD 与 DPC-FCM 的 旋转机械无监督故障诊断方法[J]. 装备环境工程, 2024, 21(1): 114-120.
  WU Y M, CHEN P, ZHANG D, et al. Unsupervised Fault Diagnosis of Rotating Machinery Based on AVMD and DPC-FCM Algorithm[J]. Equipment Environmental Engineering, 2024, 21(1): 114-120.
- [8] 王昱, 尹爱军. 基于条件变分自编码器的齿轮箱故障 诊断[J]. 装备环境工程, 2020, 17(7): 64-69.
   WANG Y, YIN A J. Fault Diagnosis of Gearbox Based on Variational Auto-Encoder with Condition[J]. Equipment Environmental Engineering, 2020, 17(7): 64-69.
- [9] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104. LEI Y G, JIA F, KONG D T, et al. Opportunities and Challenges of Machinery Intelligent Fault Diagnosis in

Big Data Era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.

[10] 邬娜, 王健, 杨建伟, 等. 变工况及小样本情况下滚动 轴承故障迁移学习方法综述[J]. 科学技术与工程, 2024, 24(10): 3939-3951.
WU N, WANG J, YANG J W, et al. Review of Rolling Bearing Migration Learning under Variable Operating

Bearing Migration Learning under Variable Operating Conditions and Small Samples[J]. Science Technology and Engineering, 2024, 24(10): 3939-3951.

- [11] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(8): 181-197.
  LI C, WU Y F, YANG S. Research Progress of Fault Diagnostics Driven by Imbalanced Data Distribution[J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 181-197.
- [12] 黄迅迪, 庞雄文. 基于深度学习的智能设备故障诊断 研究综述[J]. 计算机科学, 2023, 50(5): 93-102.
  HUANG X D, PANG X W. Review of Intelligent Device Fault Diagnosis Based on Deep Learning[J]. Computer Science, 2023, 50(5): 93-102.
- [13] 向刚, 韩峰, 周虎, 等. 数据驱动的航天器故障诊断研究现状及挑战[J]. 电子测量与仪器学报, 2021, 35(2):
   1-16.

XIANG G, HAN F, ZHOU H, et al. Data-Driven Method for Spacecraft Fault diagnosis: State of Art and Challenge[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 1-16.

 [14] 王健, 邬娜, 杨建伟, 等. 基于改进 DANN 和注意力机 制的轴箱故障诊断方法[J]. 机床与液压, 2024, 52(16):
 194-199.
 WANG J, WU N, YANG J W, et al. Axlebox Fault Di-

agnosis Method Based on Improved DANN and Attention Mechanism[J]. Machine Tool & Hydraulics, 2024, 52(16): 194-199.

[15] 田静, 沈长青, 陈再刚, 等. 基于指数调节策略对抗网络学习的轴承故障诊断研究[J]. 振动工程学报, 2024, 37(3): 476-484.
TIAN J, SHEN C Q, CHEN Z G, et al. An Exponent Adjustment Strategy Based Adversarial Network Learning

Method for Bearing Fault Diagnosis[J]. Journal of Vibration Engineering, 2024, 37(3): 476-484.

[16] 王玉静,夏林,康守强,等.基于多源域异构模型迁移的滚动轴承故障诊断方法[J].振动与冲击,2023,42(24):257-266.
WANG Y J, XIA L, KANG S Q, et al. A Fault Diagnosis Method of Rolling Bearings Based on Multi-Source Domain Heterogeneous Model Transfer[J]. Journal of Vibra-

tion and Shock, 2023, 42(24): 257-266. [17] 李翔, 陈硕, 杨健. 泛化界正则项: 理解权重衰减正则 形式的统一视角[J]. 计算机学报, 2021, 44(10): 2122-2134.

> LI X, CHEN S, YANG J. Generalization Bound Regularizer: A Unified Perspective for Understanding Weight

Decay[J]. Chinese Journal of Computers, 2021, 44(10): 2122-2134.

- [18] LIN Y, LIAN Q, ZHANG T. An Empirical Study of Invariant Risk Minimization on Deep Models[J]. In ICML 2021 Workshop on Uncertainty and Robustness in Deep Learning, 2021, 1(2): 7.
- [19] 康守强, 胡明武, 王玉静, 等. 基于特征迁移学习的变 工况下滚动轴承故障诊断方法[J]. 中国电机工程学报, 2019, 39(3): 764-772.
  KANG S Q, HU M W, WANG Y J, et al. Fault Diagnosis Method of a Rolling Bearing under Variable Working Conditions Based on Feature Transfer Learning[J]. Proceedings of the CSEE, 2019, 39(3): 764-772.
- [20] 陈仁祥, 唐林林, 胡小林, 等. 不同转速下基于深度注意力迁移学习的滚动轴承故障诊断方法[J]. 振动与冲击, 2022, 41(12): 95-101.
  CHEN R X, TANG L L, HU X L, et al. A Rolling Bearing Fault Diagnosis Method Based on Deep Attention Transfer Learning at Different Rotations[J]. Journal of Vibration and Shock, 2022, 41(12): 95-101.
- [21] 陈仁祥,朱玉清,胡小林,等. 自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J]. 仪器仪表学报,2021,42(8):95-103.
  CHEN R X, ZHU Y Q, HU X L, et al. Fault Diagnosis of Rolling Bearing under Different Working Conditions Using Adaptation Regularization Based Transfer Learning[J]. Chinese Journal of Scientific Instrument, 2021, 42(8): 95-103.
- [22] 史加荣,王丹,尚凡华,等.随机梯度下降算法研究进展[J]. 自动化学报,2021,47(9):2103-2119.
  SHI J R, WANG D, SHANG F H, et al. Research Advances on Stochastic Gradient Descent Algorithms[J]. Acta Automatica Sinica, 2021, 47(9): 2103-2119.
- [23] LESSMEIER C, KIMOTHO J K, ZIMMER D, et al. Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification[C]// Third European Conference of the Prognostics and Healthy Management Society 2016. Bilbao Spain: Prognostics and Health Management Society, 2016.
- [24] OUYANG L, KEY A. Maximum Mean Discrepancy for Generalization in the Presence of Distribution and Missingness Shift[C]// Workshop on Distribution Shifts, 35th Conference on Information Processing Systems. Montreal: [s. n.], 2021.
- [25] LONG M S, ZHU H, WANG J M, et al. Deep Transfer Learning with Joint Adaptation Networks[EB/OL]. 2016. https://arxiv.org/abs/1605.06636v2
- [26] SUN B C, SAENKO K. Deep CORAL: Correlation Alignment for Deep Domain Adaptation[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2016: 443-450.