

轴承故障模式与故障诊断方法综述

谢承辉¹, 王星¹, 肖发厚¹, 彭冬春¹, 梅燕², 刘鹏鹏²

(1. 国家能源集团江西电力有限公司 万安水力发电厂, 江西 万安 343800;

2. 成都众柴科技有限公司, 成都 610000)

摘要: 作为机械设备的关键组成部分之一, 轴承在降低运行摩擦, 为传动部件的旋转提供引导等方面具有重要作用, 并被广泛应用于农业、制造、运输等各种领域; 由于长期在高负荷、强冲击、复杂环境等情况下运行, 轴承经常会产生故障并导致设备失效, 严重时可能导致巨大经济损失和安全事故; 因此对于轴承的运行状态进行监测, 并对出现的缺陷或故障进行诊断是非常必要的; 针对上述背景, 综述了轴承的常见故障类型与故障诊断方法; 介绍了轴承的常见故障类型与导致故障的原因, 阐述了轴承故障诊断的一般流程与常用的传感器类型, 分析了 3 类故障诊断方法在轴承故障诊断中的应用与其优缺点。

关键词: 轴承; 故障类型; 故障诊断流程; 传感器; 故障诊断方法

Review of Bearing Fault Modes and Fault Diagnosis Methods

XIE Chenghui¹, WANG Xing¹, XIAO Fahou¹, PENG Dongchun¹, MEI Yan², LIU Pengpeng²

(1. Wan'an Hydropower Plant, Chn Enegry Jiangxi Power Co., Ltd., Wanan 343800, China;

2. Chengdu Zoom Check Science & Technology Co., Ltd., Chengdu 610000, China)

Abstract: As one of the key components of mechanical equipment, bearings play an important role in reducing operation-
al friction and providing guidance for the rotation of transmission components, which is widely used in agriculture, manufacturing, transportation and other fields. Due to long-term operation under high load, strong impact and complex environment, bearings often fail and lead to equipment failure, which may lead to huge economic losses and safety accidents in severe cases. Therefore, it is very necessary to monitor the running state of bearings and diagnose the defects or faults. For the above background, this paper summarizes the types and diagnosis methods of bearing faults, introduces fault types and causes of bearing faults, presents the general process of bearing fault diagnosis and the types of commonly used sensors, and analyzes the application of three kinds of fault diagnosis methods in bearing fault diagnosis and their advantages and disadvantages.

Keywords: bearing; fault type; fault diagnosis process; sensor; fault diagnosis method

0 引言

轴承是现代机械和设备的关键组成部分, 被广泛应用于各种领域, 在降低运行摩擦, 为传动部件的旋转提供引导等方面具有重要作用。根据摩擦力类型的不同, 轴承可分为两种主要类型: 滑动轴承和滚动轴承。滚动轴承根据滚动元件的形状, 可以进一步分为深沟球轴承、圆柱形滚子轴承、锥形滚子轴承和滚针轴承^[1]。

滚动轴承一般由 4 个部分组成: 内环、外环、滚动体和保持架, 如图 1 (a) 所示, 它可以将轴和轴座之间的滑动摩擦转化为滚动摩擦, 并减少摩擦损失。内环的作用是与轴进行定位和旋转。外环与轴承座相匹配, 并

起到支撑作用。因此, 在内环和外环之间存在相对的运动。保持架不仅将滚动体均匀地分布在内环和外环之间, 还可以润滑滚动体, 引导其旋转。滚动元件的形状、尺寸和数量直接影响着滚动轴承的性能和使用寿命^[2]。

滑动轴承适用于相对低速、重载和高精度的应用。在液体润滑条件下, 滑动表面被润滑油分开而不发生直接接触。轴中接触滑动轴承的部分称为轴颈, 与轴颈匹配的零件称为轴瓦, 如图 1 (b) 所示。为了提高轴瓦的摩擦性能, 通常通过浇注或烧结减摩擦材料形成轴承衬里层。滑动轴承在工作时由于轴颈与轴瓦的摩擦会导致表面发热和磨损, 因此在设计时, 通常选用减摩性好的材料制造轴瓦, 合适的润滑剂以及合适的供应方法,

收稿日期: 2023-12-29; 修回日期: 2024-02-21。

作者简介: 谢承辉(1967-), 男, 大学本科, 工程师。

通讯作者: 刘鹏鹏(1989-), 男, 硕士, 工程师。

引用格式: 谢承辉, 王星, 肖发厚, 等. 轴承故障模式与故障诊断方法综述[J]. 计算机测量与控制, 2025, 33(4): 1-9.

从而改善轴承结构并获得厚膜润滑^[3]。




图 1 轴承结构图




图 2 典型轴承故障类型

目前轴承的应用领域包括农业^[4]、采矿^[5]、制造^[6]、电力^[7]、水利^[8]、建筑^[9]及运输^[10]等。此外，轴承可用于各种环境条件下，如高温、低温、强磁场、高酸碱性环境等。随着工业的发展和需求，大多数旋转机械的工作量都很大。在高负荷、强冲击、复杂环境等情况下，轴承经常产生内、外、球等故障。轴承是导致旋转机械故障的主要原因，可占 30% 以上的比例^[11]。如果不能及时发现故障，往往会造成设备停机等严重后果，从而导致巨大的经济损失，甚至发生安全事故。

在对轴承运行过程对其进行实时监测可以有效延长使用寿命。通过分析轴承的常见故障类型，并在此基础上提出有效的故障诊断技术，可以使机械设备维持正常工作状态^[12]。所以对于轴承的运行状态进行监测，并对出现的缺陷或故障进行诊断是非常必要的^[13]，也是状态监测领域的关键挑战之一^[14]。因此，本文对轴承的常见故障类型与故障诊断方法进行了综述。

1 轴承故障类型

由于一个典型的轴承由内圈、外圈、滚动元件和保持架组成，因此轴承的故障也与这些元件有关^[15]。引起轴承故障的原因有很多，例如裂纹、机械损坏、磨损、腐蚀及润滑不足等^[16]。这些故障模式之间也存在着相互作用，如润滑不当会增加轴承的磨损，轴承部件会因磨损而逐渐变质。此外由于润滑不当，接触面之间的摩擦力增加，轴承部件的温度升高，这进一步加速了轴承破坏的过程。由于环境中湿度高，在高温下轴承极易发生表面氧化，从而产生锈蚀和凹坑等缺陷。常见的轴承故障包括断裂、磨损、腐蚀、疲劳剥落、电损伤、粘连等，如图 2 所示。

以滚动轴承为例，其典型的故障模式如下：

1) 配合失效：当外加载荷过大，干涉配合会在正常工作温度下沿径向穿过间隙时，轴承就会超负荷运行，从而导致配合过紧。而当外加载荷较小时，轴承元件之间可能会产生相对运动，从而导致配合松动^[17]。

2) 润滑失效：相关研究表明，润滑不当是 80% 的

轴承故障产生的原因。这是由于使用不合适的润滑剂会使轴承产生过高的温度，并引起其他的故障模式^[18]。

3) 污染失效：轴承的污染是由于外来颗粒进入轴承中的润滑剂或清洗剂中，从而引起摩擦力的增大。典型的外来颗粒可能包括磨砂、砂砾、污垢、灰尘、钢屑等^[19]。

4) 过热失效：轴承过热的原因主要来自润滑剂的使用不当或者过高的工作温度。在高温下，润滑油中的油脂会发生氧化，润滑油的润滑效果变差进一步导致温度升高产生恶性循环。此外，轴承金属元件的硬度会随着温度的升高而降低，大大增加了磨损的风险^[20]。

5) 疲劳剥落：轴承产生疲劳剥落的主要原因可能有不受控制的载荷、无约束的预载荷、紧凑的内环以及在特定疲劳寿命后的长期使用^[21]。

6) 腐蚀失效：含水量高、功能质量差的润滑油、不合格的覆盖层以及包裹不良和温度失控是造成轴承腐蚀失效的可能原因。腐蚀主要表现为滚珠和轴承表面的严重磨蚀，可分为点蚀和锈蚀^[22]。

7) 电损伤：当设备电路故障，有交流电或直流电恒定通过轴承元件时，即使是很低的电流，都可能会对造成电损伤^[23]。

此外，轴承还可能出现的故障类型包括塑性变形、压痕、划痕、应变、粘连、胶接、压裂、笼损伤以及氢脆等。其中腐蚀、电损伤、压痕、应变、粘附、过热烧伤等故障一般发生在工作表面^[24]。其中轴承的工作面是指滚轴体的外环、内环、滚道和表面^[25]。滚动体和滚道接触面可能会出现胶接、笼损坏等故障。环侧和滚轮端面的故障一般为划痕。氢脆通常是内外滚道表面和下表面的断裂损伤的一种。如果滚动轴承的材料中有缺陷，或者在机器操作过程中暴露于不适当的温度或过载负荷，就会发生断裂。

依据轴承故障的分布情况，其缺陷可以分为两类：局部缺陷和分布缺陷。轴承表面上的裂缝和凹坑等一般被认为是局部缺陷。而表面粗糙度、波形度、球座错位和滚动元件尺寸误差一般被认为是分布缺陷^[26]。轴承

缺陷的分布情况会影响故障诊断过程中传感器的布局，是故障诊断需要考虑的关键因素之一。

2 轴承故障诊断流程

传统的轴承故障诊断的一般流程包括数据采集、特征提取、特征选择和故障分类 4 个步骤，如图 3 所示^[27]。




图 3 轴承故障诊断流程

1) 数据采集是故障诊断的第一步，它通过传感器的信号采样过程将轴承的真实物理状态转换为可计算机操作的数字数值。这个过程采集到的数据包括从传感器系统中反映轴承健康状态的振动信号、声发射信号或电机电流信号。

2) 特征提取是对一组测量数据创建派生值（特征），这些值是有用且非冗余的，这个过程简化了学习和泛化的阶段。它将原始信号转换为统计特征，以传递有关机器状态的信息。为了获得高精度的识别结果，特征提取器的设计在模式识别的挑战中起着至关重要的作用。从机器中收集到的实际轴承故障信号一般都在时域范围内，我们可以从时域、频域和时频域的信号中提取特征。它们可以在各自的频率和时频域使用适当的变换工具进行研究。

3) 特征选择是在创建预测模型时最小化输入变量数量的过程。一般情况下，应该减少输入变量的数量，以降低建模的计算成本和提高模型的性能。特征选择一般选取最具区别性的特征，如高维特征集具有冗余和不相关的特征，这将增加学习时间，降低分类器的性能，并需要大量的计算。特征选择阶段提高了分类精度，同时也减少了计算时间。两种最常见的特征选择方法是：（1）从提取的特征集中创建一个具有较低维度的新特征集。这可以通过独立成分分析（ICA，independent component analysis）和主成分分析（PCA，principal component analysis）来实现；（2）使用特定的基准测试，删除不敏感的或不需要的特性，解决这个问题最突出的方法之一是顺序选择（SS，sequential selection）。

4) 故障分类在完成特征选择之后，将其传递到基

于学习的分类器中来检测轴承的缺陷。常用的分类器包括如 k-最近邻（KNN，k-nearest neighbor）、人工神经网络（ANN，artificial neural network）、支持向量机（SVM，support vector machine）、卷积神经网络（CNN，convolutional neural network）等。

3 传感器类型

由于故障诊断的数据采集需要通过不同的传感器来实现，因此传感器的选用对轴承的故障诊断具有重要意义^[28]。根据安装位置的不同，轴承故障检测传感器可分为外部和内部两种类型。外部安装的故障检测传感器主要包括振动信号检测传感器^[29]、温度信号检测传感器^[30]以及声发射信号检测传感器^[31]等。安装在轴承内部的传感器主要包括检测电流信号的传感器，如涡流传感器^[32]，以及检测转速、中性点电压、瞬时功率、瞬时速度、剩余信号、脉冲信号、组件信号和编码器信号的传感器^[33]。

此外，根据检测维度的不同，用于故障诊断的传感器的信号采集还可以分为一维信号检测和二维信号检测，这两种类型可以进一步分为信号传感器和图像信号传感器。一维信号传感器的检测方法是对传感器检测到的信号进行分析和诊断。用于检测一维信号的传感器主要分为以下几类：利用振动传感器中分析检测到的振动信号的参数，主要是空隙功能。此外这类传感器还可以检测谐振信号。利用声发射传感器可以测试传感器的电气参数和一次电流信号的电气参数。通常用于对负载转矩、转速、磁场频率、中性点电压、瞬时功率、瞬态转速、残余信号、脉冲信号进行分析^[34]。二维信号系统的检测方法是进行数学计算或建立模型或神经网络，将传感器检测到的信号转换为二维图像，然后对其进行分析和诊断。二维信号主要是振动图像，包括灰度图像、二维时间序列图像、复合彩色图像、雪花图像（对称图像）、多域图像等。其他方法包括声学成像、光谱成像、时频图像、红外热成像、递归图（RP，recursive plot）分析，以及使用变换矩阵到图像^[35]。

4 故障诊断方法

随着人工智能和传感器技术的不断发展，在过去的几年中，已经提出了许多轴承故障诊断方法。根据分类方法的不同可以对其进行不同的划分。

若按照传感方法进行分类，轴承故障诊断方法可以分为声学法、振动分析法、热成像法、电涡流法等。声发射法主要是利用声波的特性对轴承故障进行诊断，有声发射法和声表面波法两种方法^[36]。振动分析法是通过分析轴承的振动信号对其故障进行诊断，包括时域分析法、频域分析法和小波分析法^[37]。热成像法主要是通过红外相机检测轴承表面温度的分布，进而检测其缺

陷^[38]。电涡流法是通过轴承的涡流响应来判别故障类型与缺陷位置^[39]。不同方法的优缺点如表 1 所示。

表 1 不同轴承故障诊断方法的优缺点

分类依据	检测类别	检测方法	优点	缺点
传感方法	声学法	声发射法； 声表面波法	无需拆卸轴承	检测精度较低； 需要配合其他方法
	振动分析法	时域分析法； 频域分析法； 小波分析法	检测精度高；检测 范围广；适用于多种 工况	需要专用仪器 设备；成本较高
	热成像法	红外成像法	无需拆卸轴承；检 测速度快；适用于 各种轴承	受环境因素干扰大
	电涡流法	涡流感应法	可以检测非金属轴 承；能检测横向与 纵向缺陷	检测精度低；可 靠性差
计算机学习方法	机器学习	ANN	分类准确性好；对 于复杂非线性函数的 估计较好	约束条件较多； 训练过程不可 见
		SVM	分类准确性好；可 以处理高维数据	对于大量数据 的处理效率较 低
		kNN	使用简单；可以用 于分组和相关性	计算量较大需要 大量存储空间
	深度学习	CNN	最小化参数；轴 承故障检测不失真	训练过程复杂 且耗时
		RNN	可依赖于时间建 模；输入长度可变	梯度消失会导 致频繁的学习
		DBN	可以逐层建模	初始化与采样 困难；计算成本 最高
	迁移学习		不需要大量故障数 据；减少训练时间 和资源损耗	学习效率较低； 可能存在数据 不平衡的情况

而根据计算机学习发生对轴承故障诊断方法进行分类是目前主流的分类方法，其大致可以分为 3 类：机器学习方法、深度学习方法和迁移学习方法^[40]。

传统的基于机器学习的故障诊断方法通常包括 3 个主要步骤：数据收集、特征提取和故障分类。在数据采集步骤中，采用振动、电流、温度、声发射等各种传感器来采集反映轴承健康状态的原始数据。在特征提取步骤中，根据专家知识设计的预定义公式，手工选择和提取特征^[41]。这种非自动的特征提取步骤可能会从数据中带来不相关的或冗余的特征，而这些特征并不利于分类模型的准确性。在故障分类步骤中，通常利用一些智能方法建立特征与故障的映射关系，包括决策树^[42]、支持向量机^[43]、k-最近邻^[44]、人工神经网络^[45]等。

然而基于机器学习的故障诊断方法依赖于人工选择

有价值的特征进行故障分类，但这种劳动密集型的处理大量数据的方法很耗时。随着物联网技术的发展，可以很容易地获得大量数据与更多的故障信息，这有助于提高故障诊断的准确性^[46]。为了构建准确的故障诊断模型，尽量减少人工特征提取的成本，学者提出了直接构造故障信号与故障类别之间映射的深度学习方法。基于深度学习的故障诊断模型可以在没有先验知识的情况下从输入数据中自动学习故障特征，输出轴承的健康状态。典型的深度学习模型包括卷积神经网络^[47]、递归神经网络^[48]、受限玻尔兹曼机^[49]、自动编码器^[50]、深度信念网络^[51]等。

目前，基于深度学习的轴承故障诊断方法也存在两大问题，即数据分布与数据可用性。一方面，深度学习模型假设训练数据和测试数据遵循相同的分布，这显然与实际工作场景的条件是不同的。另外，如果测试数据来自不同的设备，即使故障类型相同，深度学习模型的故障诊断精度也可能会显著下降^[52]。另一方面，深度学习模型的性能主要依赖于标记数据的数量来进行调参，但收集和标记大量的故障数据十分困难。如果使机器在故障状态下工作来收集数据，会缩短设备的寿命并增加工作风险^[53]。对于以上问题，可以采用迁移学习方法进行数据获取与故障诊断。迁移学习放宽了训练和测试数据必须遵循相同的分布的限制，可以利用从不同但相关的任务中学到的知识来解决新的问题^[54]。在实际的轴承故障诊断场景中，由于禁止机器在轴承故障状态下长期运行，因此收集的正常数据量远远超过故障数据量，而故障数据不足会降低深度神经网络的诊断性能^[55]。因此，可以引入迁移学习来解决数据不足的问题。

机器学习、深度学习与迁移学习的流程和区别如图 4 所示。




图 4 3 种故障诊断方法对比

4.1 机器学习

4.1.1 人工神经网络（ANN）

ANN 算法被认为是应用最广泛的算法之一。ANN 算法可以分为 3 层：输入层、输出层以及隐藏层。由于隐藏层的值不可见，所以隐藏层的单元被称为隐藏单元。目前，ANN 算法已经被广泛用于轴承的故障检测，

其通过发现由隐藏层组成的历史数据模式,以大量的数据来预测目标值。从输入到输出,信息通过几个层,每一层由一个神经元连接到下一层。当一个特定的输入被引入神经网络时,神经网络产生一个唯一的输出^[56]。文献[57]基于神经网络和经验模态分解利用振动信号来进行滚动轴承的故障诊断,他们利用数学分析的方法选择了关键的固有模态函数将所选择的特征输入 ANN 来识别承载故障。文献[58]使用奇异值分解和前馈反向传播 ANN 来估计不同大小的不同轴承故障类别。在不同故障大小的健康和故障条件下,通过奇异谱图进行分析,根据负荷与故障大小的关系,选择出最具代表性的奇异值。文献[59]提出了类似的框架,其中使用具有两个隐藏层的前馈反向传播 ANN 对滚轮元件、内外圈的正常、退化和严重故障阶段进行故障分类。

4.1.2 支持向量机(SVM)

支持向量机是一种监督学习模型,一般对数据进行非概率分类和回归分析。已有研究证明 SVM 获得的分类结果在所有情况下都很好,并且完全超过了神经网络的输出^[60]。大多数基于 SVM 的轴承故障诊断也是基于振动信号进行的,其经常与连续小波变换(CWT, continuous wavelet transformation),斯托克韦尔变换(Stockwell Transform)等数据处理方法联合使用,具有简单、快速、精确的特点^[61]。文献[62]使用 SVM 作为估计轴承退化过程中健康状态概率的工具,以提供长期预测。他们利用 SVM 多分类结果中每个健康状态的概率来获得每个健康状态的概率分布。从时域和频域的经典统计参数中收集 SVM 模型的输入候选特征,在特定的健康状态下,通过在所有属性之间使用一定的距离评价标准来选择有效的特征。为了进一步提高 SVM 在轴承故障诊断中的分类准确率与诊断精度,可以通过金枪鱼群优化(TSO)算法^[63]、改进麻雀搜索算法(ISSA)^[64]、改进灰狼优化(IGWO)算法^[65]等方法对 SVM 进行优化。文献[64]提出的 ISSA-SVM 的诊断准确率比改进前的麻雀搜索算法诊断模型提高了 1.81%,比粒子群优化算法诊断模型(PSO-SVM)提高了 2.23%。

4.1.3 k-最邻近(kNN)

KNN 分类器是最基本的和简单的分类技术之一,该算法根据特征空间中样本之间的最短距离对象进行分类^[66]。KNN 适用于事先没有数据传递知识的情况,这种方法的好处是不需要对概念的属性进行任何假设,并且可以使用基本程序和局部近似来简化复杂的概念。通过重采样过程,如交叉验证或引导,可以用来评估 K 的最优值。影响 kNN 算法精度的另一个基本因素是度量的距离,它依赖于数据收集。文献[67]使用 k-NN 作为声信号分类器进行数据挖掘的中心算法基于进行陶瓷轴承的故障诊断。文献[68]利用离散小波变换的多

尺度能量分析,获得一个低维函数数据子集,作为 k-NN 的输入,进行承载故障描述。文献[69]将一种相似度量(EMD)引入到 KNN 算法中用于机车滚动轴承故障诊断,代替传统的欧式距离对故障部位进行分类,相较于传统 KNN 诊断方法在诊断准确率上提升了 0.77%。由于滚动轴承的故障信号的高噪声、非平稳特点,文献[70]先用集合模态分解法(EEMD)将轴承的震动信号进行分解此外,然后经过 kNN 的故障识别正确率达到 98.13%。

4.2 深度学习

4.2.1 卷积神经网络(CNN)

CNN 由卷积层、池化层和全连接层组成。卷积层和全连接层线性的训练一般采用线性运算和非线性运算进行,而池化层采用的是一个数学运算。在卷积层中使用一组可学习的高斯核滤波器与输入数据进行卷积,得到特征映射。池化层的目的是保持空间不变性和最小化中间函数映射的维数。通过将池操作窗口滑动到输入函数图上来指定服务区域。然后,采用数值统计方法来表示这些值,并最小化所选区域的分辨率。全连接层一般被设计为与其输入的非线性匹配^[71]。CNN 可以分为 1D-CNN 和 2D-CNN,因此其既可以处理线形数据也可以采集图像数据。文献[72]将轴承故障的原始信号转换为二维图像,并使用 CNN 来检索转换后的二维图像的特征。此外,CNN 可以直接与视觉方法结合通过学习图片信息进行轴承故障诊断^[73]。在信号降噪预处理集成方法面临高噪声环境和低质量数据挑战时难以有效地提取信号有用特征,文献[74]将多小波包分解与卷积神经网络深度融合,使模型能够多尺度地提取并学习信号有用的时频域信息,其准确率相比于普通 CNN 方法提升了 13.19%。

4.2.2 递归神经网络(RNN)

不同于 ANN 与 CNN 等前馈神经网络,RNN 的隐藏层的输出可以向其自身加载,因此 RNN 隐藏层在 t 时刻的输出即受当前时间输入也受 $t-1$ 时刻输出的影响^[75]。然而,传统的 RNN 存在一定的缺陷,RNN 跨越时间步长的设计类似于具有多个隐藏层的前馈神经网络。如果把时间步数看作是图层数量,当使用通过时间的反向传播来训练 RNN 时,错误从输出层持续到隐藏层,并从时间 t 持续到时间 1。为了解决传统 RNN 的局限性,文献[76]提出了一种新的 RNN 模型长-短期记忆循环神经网络(LSTM RNN),可以通过用 LSTM 单元替换标准 RNN 的隐藏神经元来构建神经网络。此外,文献[77]提出了另一种 RNN,利用 RNN 层中的 LSTM 单元来估计轴承的剩余寿命。除了时频特征外,相关相似度特征还估计了当前管理数据与起始操作点的数据之间的相似度。采用相关性和单调性特征

选择程序对相关特征进行识别和选择,然后利用这些特征训练 RNN 网络进行轴承诊断并计算剩余寿命。

4.2.3 深度信念网络 (DBN)

一个 (DBN) 是由多个受限玻尔兹曼机 (RBM) 组成的。第一个 RBM 由第一个隐藏层 h_1 和可见层 v 组成,第二个 RBM 由第一隐藏层 h_1 和第二隐藏层 h_2 组成,第三 RBM 由第二隐藏层 h_2 和第三隐藏层 h_3 组成,依此类推^[78]。在轴承故障诊断中,可以结合多传感器振动数据融合方法来实现。文献 [79] 使用一个三层的 DBN 来对数据进行分类,利用不同速度下的振动数据验证所提出的方法,显示出 97.82% 的准确率,这种方法可以正确诊断在各种操作条件下的轴承故障问题。文献 [80] 利用改进的自适应噪声完全集合经验模态分解 (ICEEMDAN) 与小波阈值相结合的方法去除轴承振动信号中的伪迹,提取信号的线性和非线性特征并将多域特征作为输入项,利用 DBN 进行训练识别,建立了能够有效识别轴承故障类型的模型,结果表明该模型对轴承故障类型识别的正确率可达 97.8%。

4.3 迁移学习

前文提到,获取大量的故障数据十分困难,且使机器在故障状态下工作收集数据会缩短设备的寿命,因此可以采用迁移学习方法进行数据获取与故障诊断。迁移学习的两个基本要素是任务和域^[81]。每个域由两个分量组成,即特征空间和边际概率分布。域可以分为目标域和源域,用于训练基础模型的源域有大量的标记数据和知识,给定知识并转移的对象是目标域。任务由标签空间和目标预测函数两个元素组成,任务也可以分为目标域任务和源域任务^[82]。基于目标与源任务及域之间的迁移特征不同,迁移学习技术可以分为实例迁移、特征表示迁移、参数迁移与关系知识迁移^[83]。

目前,迁移学习方法也已经广泛用于轴承故障检测。文献 [84] 提出了一种基于深度生成对抗网络的跨域迁移学习故障诊断技术,合成伪样本并进行域自适应。当测试数据不适用于训练时,该模型提供了有效的跨领域诊断结果。文献 [85] 提出了一种迁移模型来解决承载缺陷识别所需的大量训练数据,使得在较少数据下表现良好。该模型使用来自相同或不同类别的样本对,计算两个双胞胎特征向量输出之间的距离。在 90 个训练样本的简短训练集中,该方法可以达到 92.56% 的准确率。文献 [86] 提出一种基于联邦模型迁移的不同规格滚动轴承故障诊断框架。该方法对多个用户振动数据做短时傅里叶变换,构建时频图数据集,各用户训练本地模型并将模型参数上传至服务器。该方法在数据孤岛和标签稀缺的前提下,可实现不同规格滚动轴承故障诊断,并具有较高的准确率和良好的泛化性能。

表 1 对比了不同轴承故障诊断方法的优缺点,每种

故障诊断方法在不同场景下具有不同的应用效果。机器学习需要预先进行数据处理,由人工进行特征选取,深度学习可以很好地避免这一缺陷。但在深度学习中,大量故障数据的获取是十分困难的,因为机器不能长期在故障状态下工作,而迁移学习方法可以很好地解决这个问题,通过跨域学习实现轴承的故障诊断,减少了耗时和深入的模型操作。

5 未来发展趋势

目前,关于轴承故障诊断的各类方法已经相对成熟,下一步的发展趋势主要包括:

1) 基于数字孪生的轴承智能运维:随着数字孪生与智能制造技术的快速发展,轴承的故障实时诊断与维修也将实现智能化。基于实时的数据分析与基于数字孪生的智能预测,可以实现轴承的实时在线检测与诊断,提前预测可能出现的轴承故障,将维修成本与停机损失降到最低。

2) 基于多方法融合的故障诊断:智能诊断技术是轴承故障诊断未来的一个重要研究方向。而为了提高诊断的准确率与精度,需要将多种不同的智能诊断方法进行结合,例如将专家系统与神经网络结合。

3) 开发远程故障诊断系统:随着计算机和网络技术的发展,远程故障诊断将是轴承故障诊断的一个重要发展方向。采用多台计算机设备作为服务器,在多个关键轴承上设立监测点,采集轴承状态数据,有利于进一步促进轴承机械的在线管理。

6 结束语

本文对轴承的常见故障类型、故障诊断流程以及常用的故障诊断方法进行了综述。在故障类型方面,常见的故障类型包括润滑失效、过热、疲劳剥落、腐蚀、电损伤、塑性变形、压痕、划痕、应变、粘连、胶接、压裂、笼损伤以及氢脆等。针对这些故障类型,轴承的故障诊断流程主要包括数据采集、特征提取、特征选择以及故障分类。在数据采集方面,针对不同的故障类型需要采用不同的传感器进行故障数据获取,主要包括振动传感器、温度传感器、声发射传感器、电极传感器以及视觉传感器等。在故障诊断方法方面,主要有机器学习、深度学习和迁移学习 3 种类型。其中常用的机器学习方法有人工神经网络、支持向量机、k 最邻近等;常用的深度学习方法包括卷积神经网络、递归神经网络和深度信念网络等,而迁移学习将是未来轴承故障诊断最重要的方向之一。

参考文献:

- [1] XU F, DING N, LI N, et al. A review of bearing failure modes, mechanisms and causes [J]. Engineering Failure

- Analysis, 2023, 152: 107518.
- [2] STORTI G C, TUCKMANTEL F W D S, MACHADO T H. Modal parameters identification of a rotor-journal bearing system using operational modal analysis [J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2021, 43 (3): 148.
- [3] NADIA B, KADDA M. Numerical analysis of the fluid flow behavior in the plain journal bearing at textured and not textured surface [J]. International Journal of Surface Engineering and Interdisciplinary Materials Science, 2021, 9 (1): 40 - 59.
- [4] JOTAUTIENE E, JUOSTAS A, BHANDARI S. proper technical maintenance of combine harvester rolling bearings for smooth and continuous performance for grain crop agro-technical requirements [J]. Applied Science, 2021, 11: 8605.
- [5] KOROTKOV A, KOROTKOVA L, VOETH S, et al. Steel quality of rolling contact bearings produced by different manufacturers, used for mining equipment instrumentation [J]. EDP Sciences, 2021, 315: 03019.
- [6] MURCINKOV á, ZUZAN A, MURCINKO J. Bearing units and surface micro-geometry of rolling races in textile machinery [J]. Applied Mechanics & Materials, 2014, 616: 27 - 34.
- [7] KARNAVAS Y L, PLAKIAS S, CHASIOTIS I D. Extracting spatially global and local attentive features for rolling bearing fault diagnosis in electrical machines using attention stream networks [J]. IET Electric Power Applications, 2021, 15: 903 - 915.
- [8] MAYOOF F N. Beating phenomenon of multi-harmonics defect frequencies in a rolling element bearing: case study from water pumping station [J]. World Academy of Science Engineering & Technology, 2009, 3: 1062 - 1066.
- [9] HAN L, BELIVANIS K V, HELWIG T A, et al. Field and computational investigation of elastomeric bearings in high-demand steel girder application [J]. Journal of Constructional Steel Research, 2019, 162: 105758.
- [10] LI X, HE M, JIA L, et al. Sparse fast fourier transform and its application in intelligent diagnosis system of train rolling bearing [J]. Journal of Vibroengineering, 2015, 17 (8): 4219 - 4230.
- [11] 杨雅奇, 张彩红, 林繁云. 滚动轴承故障诊断技术综述 [J]. 山东化工, 2021, 50 (21): 83 - 84.
- [12] 韦洪新. 滚动轴承故障诊断研究方法及进展 [J]. 天津理工大学学报, 2021, 37 (2): 36 - 40.
- [13] SLAVI C, JANK O, BRKOVI C, et al. Typical bearing-fault rating using force measurements: application to real data [J]. Journal of Vibration & Control, 2011, 17 (14): 2164 - 2174.
- [14] UMEMURAM, TAKENAKA C. Biological cycle of sili-con in Moso bamboo (*Phyllostachys pubescens*) forests in central Japan [J]. Ecol Res, 2014, 29 (3): 501 - 510.
- [15] MALLA C, PANIGRAHI I. Review of condition monitoring of rolling element bearing using vibration analysis and other techniques [J]. Journal of Vibration Engineering & Technologies, 2019, 7: 407 - 414.
- [16] TANDON N, NAKRA B C. Vibration and acoustic monitoring techniques for the detection of defects in rolling element bearings-a review [M]. Macmillan Press, 1992, 24: 3 - 11.
- [17] 郑康, 朱明敏, 宋森楠, 等. 发动机各主轴承间隙配合对其振动特性的影响 [J]. 机械制造与自动化, 2023, 52 (3): 58 - 61.
- [18] 郑远春. 基于油液监测的轴承润滑状态综合评估 [J]. 中国修船, 2023, 36 (5): 50 - 53.
- [19] 史俊杰, 王熠, 何代全, 等. 烟草设备齿轮箱润滑油污染物状态分析 [J]. 设备管理与维修, 2023 (19): 180 - 182.
- [20] 王轩. 浅谈如何预防客车热轴风险 [J]. 哈尔滨铁道科技, 2023 (2): 20 - 23.
- [21] 王潇, 马军, 熊新, 等. 含滚道剥落缺陷的滚动轴承动力学建模及分析 [J/OL]. 北京航空航天大学学报: 1 - 15 [2023 - 12 - 07]. <https://doi.org/10.13700/j. bh. 1001-5965. 2023. 0565>.
- [22] 王娇娇, 刘泳, 刘宏春, 等. GCr15 轴承钢酸洗腐蚀麻点成因分析 [J]. 工业加热, 2023, 52 (6): 71 - 73.
- [23] 孙毓明, 宋晨飞, 孙逸翔, 等. 滚动转速对 GCr15 钢载流摩擦电损伤的影响 [J]. 河南科技大学学报 (自然科学版), 2019, 40 (3): 6 - 10.
- [24] FANG Q, QIAO B, YU M. A study on the feature separation and extraction of compound faults of bearings based on casing vibration signals [J]. Journal of Vibroengineering, 2021, 23: 1737 - 1752.
- [25] SHUKLA R, KANKAR P K, PACHORI R B. Automated bearing fault classification based on discrete wavelet transform method [J]. Life Cycle Reliability and Safety Engineering, 2020, 10: 99 - 111.
- [26] 周泽文. 含局部缺陷的滚动轴承动力学建模及振动特性研究 [D]. 南昌: 南昌航空大学, 2023.
- [27] MUSHTAQ S, ISLAM M M, SOHAIB M. Deep learning aided data-driven fault diagnosis of rotatory machine: a comprehensive review [J]. Energies, 2021, 14: 5150.
- [28] WU G, YAN T, YANG G, et al. A review on rolling bearing fault signal detection methods based on different sensors [J]. Sensors, 2022, 22: 8330.
- [29] GUNERKAR R, JALAN A. Classification of ball bearing faults using vibro-acoustic sensor data fusion [J]. Experimental Techniques, 2019, 43: 635 - 643.

- [30] ZHANG P, PAN A, YAN K, et al. High-efficient and reversible temperature sensor fabricated from highly luminescent CdTe/ZnS-SiO₂ nanocomposites for rolling bearings [J]. *Sensors & Actuators A: Physical*, 2021, 328: 112758.
- [31] YU Q, DAI L, XIONG R, et al. Current sensor fault diagnosis method based on an improved equivalent circuit battery model [J]. *Applied Energy*, 2022, 310: 118588.
- [32] DADOUCHE A, REZAEI A, WICKRAMASINGHE V, et al. Sensitivity of air-coupled ultrasound and eddy current sensors to bearing fault detection [J]. *Tribology Transactions*, 2008, 51: 310–323.
- [33] SHINGO T, NOBUHIKO H. New method using piezoelectric jerk sensor to detect roller bearing failure [J]. *International Journal of Automotive Technology*, 2013, 7: 550–557.
- [34] LIU X, HUANG H, XIANG J. A personalized diagnosis method to detect faults in a bearing based on acceleration sensors and an FEM simulation driving support vector machine [J]. *Sensors*, 2020, 20: 420.
- [35] DUAN Z, WU T, GUO S, et al. Development and trend of condition monitoring and fault diagnosis of multi-sensors information fusion for rolling bearings: a review [J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 96: 803–819.
- [36] 周泽俊. 轴承故障声发射信号噪声与特征识别方法研究 [D]. 沈阳: 沈阳工业大学, 2023.
- [37] 杨 岗, 徐五一, 邓 琴, 等. 基于振动信号的滚动轴承复合故障诊断研究综述 [J]. *西华大学学报 (自然科学版)*, 2024, 43 (1): 48–69.
- [38] 王建鑫, 郭佑民, 杨 君. 滚动轴承红外热成像故障诊断与状态监测 [J]. *红外技术*, 2023, 45 (10): 1045–1051.
- [39] 王振飞. 基于低频涡流检测的轴承钢识别与分类方法研究 [D]. 杭州: 浙江理工大学, 2023: 10–40.
- [40] CHEN X, YANG R, XUE Y, et al. Deep transfer learning for bearing fault diagnosis: a systematic review since 2016 [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3508211.
- [41] YU X, DONG F, DING E, et al. Rolling bearing fault diagnosis using modified LFDA and EMD with sensitive feature selection [J]. *IEEE Access*, 2018, 6: 3715–3730.
- [42] 张天瑞, 赵伟博, 周福强, 等. 一种基于改进极端梯度提升决策树的轴承故障诊断方法 [J]. *重庆师范大学学报 (自然科学版)*, 2023, 40 (5): 30–39.
- [43] 王 栋, 张力丹, 李 峰. 基于软性核凸包支持向量机算法滚动轴承故障诊断分析 [J]. *机械设计与研究*, 2023, 39 (5): 92–94.
- [44] 杨铭轩, 于亚雄, 李 青, 等. 基于 KNN 的水轮机组轴承监测与故障诊断 [J]. *自动化与仪器仪表*, 2023, 4: 66–70.
- [45] 邹 旺, 江 伟, 冯俊杰, 等. 基于 ANN 和 SVM 的轴承剩余使用寿命预测 [J]. *组合机床与自动化加工技术*, 2021, 1: 32–35.
- [46] LEI Y, YANG B, JIANG X, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap [J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106587.
- [47] 谭启瑜, 马 萍, 张宏立. 基于图卷积神经网络的滚动轴承故障诊断 [J]. *噪声与振动控制*, 2023, 43 (6): 101–108.
- [48] 施保华, 吴 婷, 赵子睿. 基于递归图和增强残差网络的轴承故障诊断 [J]. *轴承*, 2024 (12): 87–94.
- [49] 孙世岩, 张 钢, 梁伟阁, 等. 基于改进受限玻尔兹曼机的滚动轴承健康因子构建方法 [J]. *系统工程与电子技术*, 2023, 45 (9): 2979–2985.
- [50] 喻奎达, 李 峰, 张国强. 混沌萤火虫参数优化去噪自动编码器在轴承故障诊断中应用 [J]. *中国工程机械学报*, 2023, 21 (3): 271–275.
- [51] 叶 楠, 常佩泽, 张露予, 等. 基于改进后半监督深度信念网络的多工况轴承故障诊断研究 [J]. *机械工程学报*, 2021, 57 (15): 80–90.
- [52] LI C, ZHANG S, QIN Y, et al. A systematic review of deep transfer learning for machinery fault diagnosis [J]. *Neurocomputing*, 2020, 407: 121–135.
- [53] XIAO D, HUANG Y, ZHAO L, et al. Domain adaptive motor fault diagnosis using deep transfer learning [J]. *IEEE Access*, 2019, 7: 80937–80949.
- [54] PAN S AND YANG Q. A survey on transfer learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22 (10): 1345–1359.
- [55] YU N, YANG R, HUANG M. Deep common spatial pattern based motor imagery classification with improved objective function [J]. *International Journal of Network and Dynamic Intelligence*, 2022, 1 (1): 73–84.
- [56] AMAR M, GONDAL I, WILSON C. Vibration spectrum imaging: a novel bearing fault classification approach [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62 (1): 494–502.
- [57] TIAN Y, MA J, LU C, WANG Z. Rolling bearing fault diagnosis under variable conditions using LMD-SVD and extreme learning machine [J]. *Mechanism and Machine Theory*, 2015, 90: 175–186.
- [58] MURUGANATHAM B, SANJITH M, KRISHNAKUMAR B, et al. Roller element bearing fault diagnosis using singular spectrum analysis [J]. *Mechanical Systems and Signal Processing*, 2013, 35 (12): 150–166.
- [59] ALI J, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration

- signals [J]. *Applied Acoustics*, 2015, 89: 16–27.
- [60] DONG S, XU X, LIU J, et al. Rotating machine fault diagnosis based on locality preserving projection and back propagation neural network-support vector machine model [J]. *Measurement & Control*, 2015, 48 (7): 211–216.
- [61] MOOSAVIAN A, JAFARI SM, KHAZAEI M, et al. A comparison between ANN, SVM and least squares SVM: Application in multi-fault diagnosis of rolling element bearing [J]. *International Journal of Acoustics and Vibration*, 2018, 23: 432–440.
- [62] KIM H, TAN A, MATHEW J, et al. Bearing fault prognosis based on health state probability estimation [J]. *Expert Systems with Applications*, 2012, 39 (5): 5200–5213.
- [63] 张叶凯, 胡亮, 丰亚辉, 等. 基于TSO优化SVM的滚动轴承故障诊断 [J]. *煤矿机械*, 2023, 44 (12): 168–172.
- [64] 文征, 段俊勇, 杨化林. 基于改进麻雀搜索算法优化SVM的轴承故障诊断研究 [J]. *舰船电子工程*, 2023, 43 (9): 151–155.
- [65] 刘谨言, 买买提热依木·阿布力孜, 项志成, 等. 基于改进的灰狼优化算法与SVM风机轴承故障诊断 [J]. *机械传动*, 2023, 47 (9): 160–169.
- [66] HUI K, OOI C, LIM M, et al. A hybrid artificial neural network with dempster-shafer theory for automated bearing fault diagnosis [J]. *Journal of Vibroengineering*, 2016, 18: 4409–4418.
- [67] AN Z, LI S, WANG J, et al. Generalization of deep neural network for bearing fault diagnosis under different working conditions using multiple kernel method [J]. *Neurocomputing*, 2019, 352: 42–53.
- [68] YUAN H, WANG X, SUN X, et al. Compressive sensing-based feature extraction for bearing fault diagnosis using a heuristic neural network [J]. *Measurement Science and Technology*, 2017, 28: 065018.
- [69] 王嘉浩, 罗倩, 胡园园. 基于KNN-EMD算法的机车轴承故障诊断方法 [J]. *计算机仿真*, 2021, 38 (11): 129–132.
- [70] 姚武军, 孙文, 曹菊英. 基于EEMD和KNN的滚动轴承故障诊断研究 [J]. *信息技术与信息化*, 2020, 6: 112–115.
- [71] QIAO M, YAN S, TANG X, et al. Deep convolutional and LSTM recurrent neural networks for rolling bearing fault diagnosis under strong noises and variable loads [J]. *IEEE Access*, 2020, 8: 66257–66269.
- [72] ZHANG J, SUN Y, GUO L, et al. A new bearing fault diagnosis method based on modified convolutional neural networks [J]. *Chinese Journal of Aeronautics*, 2020, 33: 439–447.
- [73] 郭渊, 周俊. 基于机器视觉的轴承缺陷检测研究进展 [J]. *机电工程*, 2024, 41 (5): 761–774.
- [74] 陶唐飞, 周文洁, 况佳臣, 等. 融合多小波分解的深度卷积神经网络轴承故障诊断方法 [J]. *西安交通大学学报*, 2024, 58 (5): 31–41.
- [75] JIANG H, LI X, SHAO H, et al. Intelligent fault diagnosis of rolling bearings using an improved deep recurrent neural network [J]. *Measurement Science and Technology*, 2018, 29 (6): 065107.
- [76] SHENFIELD A, HOWARTH M. A novel deep learning model for the detection and identification of rolling element-bearing faults [J]. *Sensors*, 2020, 20 (18): 1–24.
- [77] GUO L, LI N, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings [J]. *Neurocomputing*, 2017, 240: 98–109.
- [78] SHAO H, JIANG H, LI X, et al. Rolling bearing fault detection using continuous deep belief network with locally linear embedding [J]. *Computers in Industry*, 2018, 96: 27–39.
- [79] CHEN Z, LI W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66 (7): 1693–702.
- [80] 刘雨轩, 王琳, 张鹏镇, 等. 基于深度置信网络的轴承故障识别分析与研究 [J]. *沈阳工程学院学报 (自然科学版)*, 2023, 19 (4): 84–89.
- [81] YAN R, SHEN F, SUN C, et al. Knowledge transfer for rotary machine fault diagnosis [J]. *IEEE Sensors Journal*, 2020, 20 (15): 8374–8393.
- [82] LI X, HU Y, LI M, et al. Fault diagnostics between different type of components: a transfer learning approach [J]. *Applied Soft Computing Journal*, 2020, 86: 105950.
- [83] SUN M, WANG H, LIU P, et al. A sparse stacked denoising autoencoder with optimized transfer learning applied to the fault diagnosis of rolling bearings [J]. *Measurement: Journal of the International Measurement Confederation*, 2019, 146: 305–314.
- [84] LI X, ZHANG W, DING Q. Cross-domain fault diagnosis of rolling element bearings using deep generative neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66 (7): 5525–5534.
- [85] ZHAO B, ZHANG X, ZHAN Z, et al. Deep multi-scale convolutional transfer learning network: a novel method for intelligent fault diagnosis of rolling bearings under variable working conditions and domains [J]. *Neurocomputing*, 2020, 407: 24–38.
- [86] 康守强, 肖杨, 王玉静, 等. 基于联邦模型迁移的不同规格滚动轴承故障诊断方法 [J]. *振动与冲击*, 2023, 42 (22): 184–192.