

数据驱动的轴承早期故障诊断技术综述

李兆飞^{1,2}

(1 四川轻化工大学 自动化与信息工程学院, 四川 宜宾 643002)

(2 人工智能四川省重点实验室, 四川 宜宾 643002)

摘要 轴承早期故障的实时诊断, 是实际工程应用需求和基础科学问题研究的交汇点, 是轴承故障诊断的发展方向之一。首先, 阐述了轴承故障及演变过程; 其次, 根据轴承早期故障实时诊断的需求, 总结了轴承早期故障诊断难点问题; 之后, 重点论述了轴承早期故障诊断3个关键环节所采用的各种技术: 微小监测信号增强技术、监测数据的融合表示技术以及早期故障智能诊断技术; 最后, 总结展望了轴承早期故障诊断技术的发展趋势。

关键词 轴承 微小故障 早期故障诊断 盲源分离 深度迁移学习

A Survey of Incipient Fault Diagnosis of Bearings Based on Data-drive

Li Zhaofei^{1,2}

(1 College of Automation and Information Engineering, Sichuan University of Science & Engineering, Yibin 643002, China)

(2 Artificial Intelligence Key Laboratory of Sichuan Province, Yibin 643002, China)

Abstract On-line real time diagnosis of bearing incipient faults is the intersection of practical engineering application requirements and basic scientific research. It is one of the development directions of bearing fault diagnosis at home and abroad. Firstly, this study analyzes the bearing fault and its evolution process; secondly, according to the needs of bearing incipient fault diagnosis in time, the difficult problems of bearing incipient fault diagnosis are summarized; then, it focuses on the various technologies used in the three crucial links of bearing early fault diagnosis: the weak monitoring signal enhancement technology, the fusion representation technology of monitoring parameters and the early fault intelligent diagnosis technology; finally, the development trend of bearing incipient fault diagnosis technology is summarized and prospected.

Key words Bearing Minor fault Incipient fault diagnosis Blind source separation Deep transfer learning

0 引言

随着国民经济及社会建设的持续、快速发展, 轴承已成为各种大型复杂装备(高速列车、高精度数控机床、高速压缩机组、航空航天装备、核电及大型风电机组等)应用最普遍、最易损坏的配套件和基础件, 被称为装备的关节。据统计, 各种复杂装备的故障约30%是由轴承引起的, 其运行状态直接影响着整套装备的性能^[1]。国内外因轴承故障所引发的灾难性安全事故时有发生。1970年至2000年, 国内外公开报道的因轴承故障引发的安全事故就达到50多起^[2]; 据尉询楷等^[3]的统计, 2005年至2013年, 我军某型新机列装后累计发生数十起因主轴承损伤导

致的发动机严重故障, 多次空中停车迫降和数起二等重大飞行事故, 直接经济损失达数十亿元。

研究表明, 即使是热处理、制造工艺相同的同批轴承, 在相同工况下, 其寿命离散程度仍相当高。其结果是, 在工程实际中, 某些轴承虽然还远未达到设计使用寿命就已经出现故障, 若只简单地以设计寿命为标准定时检修, 势必会造成维修的不及时, 甚至引发重大的安全事故; 反之亦然^[4]。此外, 轴承从故障出现发展到可检测的水平是一个量变的过程, 甚至可能在出现可检测的故障现象之前就已经完全损毁。并且, 由于轴承运行环境的独特性和诱发故障的多源性, 轴承的损伤情况及原因是极其复杂的。若轴承发生故障, 通常不只是单一故障, 可能是几

种故障的耦合。轻微故障可由轴承的工作表现呈现，而一旦发生显著性故障就会严重损伤轴承甚至使轴承报废，无法识别出原始痕迹。

鉴于轴承在工程实际中存在的现象，人们一直期望能够对损失和事故的发生与发展做到“防微杜渐，防患于未然”。在轴承故障刚刚出现或故障程度尚轻微时，实时准确地识别和诊断，并据此指导保养和维修工作，及时采取措施，防止造成严重损失，一直是轴承故障诊断研究的重点和难点。这不仅有助于提高复杂装备的安全运转率，减少重大事故危害，还能获得潜在的社会和经济效益，具有相当普遍的意义。

1 轴承故障及演变过程

故障是指系统中部分元器件功能失效而导致系统不能执行规定功能的状态；是指在一个过程中，观测变量或计算参数对可接受范围的偏离。轴承出现故障时，会发生振动和噪声加剧，局部温度上升和油液改变等突然的变化现象。现有认知认为，轴承主要故障形式有疲劳剥落、塑性变形、断裂、烧伤、锈蚀及胶合等。根据获取有效监测信号的途径划分，常用的基于数据驱动的轴承故障诊断方法主要有：温度监测法、油液监测法、声发射方法、油膜电阻诊断法、光纤监测诊断法、间隙测定诊断法、机器视觉监测法、力矩监测法以及振动监测法等^[5]，随着科技的发展，对轴承各种故障形式均可采用专用传感器进行监测。基于数据驱动的轴承故障诊断过程如图1所示，具体实施过程又可分为信息采集、信息处理（特征提取）、状态辨识与诊断决策4个步骤^[6]。目前，国内外对轴承的监测主要集中在振动、温度等单一参数，一般是采用将传感器安装在轴承座上或箱体适当位置的外挂式方式，轴承产生故障的位置距离传感器安装位置较远，信号在传输过程中容易存在能量损耗^[7]，尤其在采集轴承振动信号时，信号是通过轴承座或其他零部件传递到传感器，信号在传输过程中容易衰减，不易检测到早期故障信号^[8]；此外，传感器采集的信号包含轴承自身和其他部件的运行状态信息，出现早期故障时信号微弱，当背景噪声足够大时，早期故障容易被掩盖，这给轴承早期故障诊断带来了挑战。并且，一种传感器采集的监测参数只能表征某一种运行特征，对轴承整体运行状态的描述不充分^{[9][13]}。

根据轴承故障的演变过程，可分为微小故障和显著性故障。微小故障通常具有幅值低、故障特性不明显、易被未知扰动和噪声掩盖等特点^{[10][17]}。一

方面包括始终偏离正常运行状态程度较小，经过时间的积累，却可危及装备安全运行的潜在故障或称为缓变故障，如轴承磨损故障；另一方面包括对系统性能影响较小的早期故障或称为突变故障，早期故障在故障演变过程中有幅值限制，一旦超过最大值就发展为显著故障；此外，还有一种大多与原件或装备的逐渐退化有关且幅值小、随时间的推移时隐时现的间歇微弱故障^{[10][18]}。微小故障具有隐蔽性和随机性，初期特征极其不明显，但任何一个局部的微小故障都可能通过设备及子系统之间的连通路经进行传播和扩散，经演变导致装备的误报警或误切换。特别是早期微小故障，有可能在短时间内突变至较大幅值，进而导致系统性能退化^[11]。

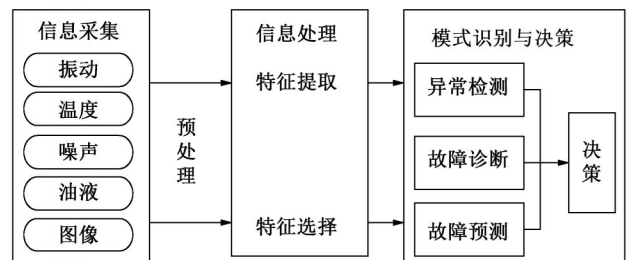


图1 基于数据驱动的轴承故障诊断过程

Fig. 1 Process of bearing fault diagnosis based on data drive

轴承的早期微小故障诊断研究得到了众多知名学者的关注及国家自然科学基金的大力资助，其研究思路主要集中在数据驱动的方向上（传统基于机理建模的诊断方式不能完全适应轴承故障诊断问题），但研究尚处于初级阶段，需要众多学者共同努力，进一步推动该研究的开展^{[12][9]}。本文论述的轴承早期故障均假定故障可被感知并能被分离。可被感知是指早期故障在一定程度上影响设备的状态和输出；能被分离是指依据现有信息可以指示故障发生部位和发生机理。

2 轴承早期故障诊断难点

本质上，早期故障与微小故障是不同的概念，微小故障与显著故障也是相对而言的。在故障存在的前提下，现有的诊断方法识别不出的故障即可被视为微小故障。而早期故障是一个渐进演化的过程，随着轴承所在设备的正常运行与损耗，经过累积和演化，逐步发展成为显著故障。轴承早期故障通常具有很强的破坏性、隐蔽性、随机性和复杂性，主要体现在以下几个方面：①故障影响轻微，对系统性能影响不明显，但不加处置容易迅速恶化或引发继发故障造成更严重的损失；②故障征兆信号微弱，易被系统未知扰动和强噪声掩盖；③同一工况下，轴承正常及故障运行状态的变化十分微小；④故障

特征可分性弱,故障特征不显著且相互耦合,故障诊断十分困难。由于早期故障和微小故障都有幅值小的特点(特殊情况除外),故有时会不加区分地把两种故障视为同一概念。相对于传统的轴承故障诊断,早期故障诊断是一类更精细的诊断方式,需要增大故障与噪声之间的信噪比,去除扰动和噪声对微小故障的掩盖,因而诊断难度更大,要求更高。目前,轴承早期故障诊断研究存在以下共性难点问题:

(1) 故障征兆信号微弱,征兆信息难获取。受信号传播途径、传播介质、传感器安装位置数量的限制和传感器正常损耗等因素的影响,轴承早期故障征兆信号获取十分困难。

(2) 运行监测参数较多,运行状态难描述。在早期故障阶段通常会采用尽可能多的传感器对轴承状态进行全面监测。但监测信号数量多、种类差异大、采样策略形式多,早期故障信息时隐时现,随机因素干扰多,导致数据质量参差不齐,监测数据呈现高维度、强相关、多模态、不确定、低密度等特性,仅通过获取的参数很难准确、全面地评判轴承的实际运行状况。

(3) 故障特征可分性弱,微小故障难诊断。轴承处于早期故障时,故障特征不明显;轴承作业环境复杂,作业过程多工况交替,其运行状态和早期故障特征具有强非线性关系;轴承所处装备结构复杂,部件间存在机、电、液、磁、气、固等多尺度、多能域的多重复杂耦合关系,所监测的大量无标签状态信息混叠,导致不同类型的微小故障耦合,难以识别和区分。

本文从数据驱动的思路出发,针对大型复杂装备普遍采用的关键部件轴承早期故障诊断共性难点问题展开综述,对轴承早期故障诊断主要包含的3个关键环节进行分析。希望能在轴承早期故障诊断共性难点问题和技术上给出进一步的研究方向,促进轴承早期故障诊断研究工作的开展。

3 轴承早期故障微小监测信号增强技术

工程中,由于采集路径较长易导致信号衰减严重;轴承早期微小故障阶段被其他噪声严重干扰;早期微小故障阶段多故障耦合等,故障征兆往往表现得非常微小^[13]。监测信号呈非高斯、非平稳性,而传统的基于平稳、高斯信号理论的方法(如谱分析、包络分析等)主要被用来获取征兆显著的信号^[14],不再适用于轴承早期故障诊断。如何设计有效算法增大监测信号与噪声之间的信噪比,去除扰动和噪声对信号的掩盖,增强微小监测信号,是轴

承早期故障诊断的基础。目前,适用于微小监测信号增强的典型方法有:高阶统计量、随机共振、小波变换、时域同步平均、经验模态分解、变分模态分解及盲源分离等。

3.1 高阶统计量(Higher-order Statistics, HOS)

高阶统计量是20世纪60年代提出的,用于对信号3阶及更高阶统计特性进行分析的方法,自1995年以来,Fackrell发现双谱分析结果不受测点位置的影响,能够提取信号的非线性信息,对于结构对称且具有固定载荷区间的轴承,其循环统计特征量随时间表现出周期或多周期变化过程^[15-16]。常用的循环统计量主要有谱相关密度函数、自相关函数及切片分析等。受强背景噪声影响,轴承早期微小故障信号的随机循环平稳特征用常规方法很难提取。Dong等^[17]提出了一种循环双谱的方法,之后又提出了一种谱移双谱法,成功提取了滚动轴承故障特征。此外,程静等^[18]将双谱分析应用到轴承故障诊断中,取得不错的效果。虽然高阶统计量(尤其是双谱)能有效分离有用信号和噪声信号,适合轴承的微小故障分析,得到了较多的研究和应用^[19-20],但该方法的前提条件是要求已知噪声分布模型,否则,分离效果较差。

3.2 随机共振方法(Stochastic Resonance, SR)

随机共振理论(SR)是意大利学者Benzi在解释冰期周期性递归时首次发现和提出的,20世纪90年代,随机共振成功用于微小信号特征提取^[21]。随机共振不像传统方法抑制或消除噪声,而是利用噪声中的部分能量转化为信号能量,达到增强信号中微小成分的目的。Liu等^[22]发表了一种基于三稳系统和随机共振机理的轴承早期微弱故障检测方法。Zhang等^[23-24]分别从不同的方面改进随机共振理论并应用于增强轴承故障特征,表现出了较好的效果,然而,随机共振存在滤波性能有限、只适用于检测极低频信号的约束及信号特征频率(Frequency Characteristics, FC)先验条件参数不足的缺陷。

3.3 小波变换法(Wavelet Transform)

傅里叶变换的缺点是分辨率单一,而小波变换在时频域均能表征信号的局部特征,被誉为“数学显微镜”,通过不断变换尺度,可以检测出信噪比较低的非平稳、非线性微小特征信号。近30年来,性能更好的小波基和小波函数不断被提出,在故障诊断领域得到空前的发展和巨大的成功。乔志城等^[25]采用改进经验小波变换结合最小熵解卷积对铁路轴承故障进行了诊断应用。郑近德等^[26]将小波变换用于轴承故障诊断,取得了不错的效果。然而,小波

变换多数是采用 Mallat 算法的无冗余的正交变换, 在每做下一级尺度分解时, 点数都比上一级减半, 是有抽取的二进小波分解, 虽然能完整地重构原始信号, 但轴承诊断的主要目的是信号检测和特征提取, 采用无冗余的正交小波变化反而容易造成漏检和误判^[27]。为弥补这种缺陷, 冗余的连续小波变换越来越受到研究者的重视。另外, 如何选取合适的小波基函数(对降噪效果影响很大), 仍然会是未来需要很长一段时间解决的难题。

3.4 时域同步平均法(Time Synchronous Average, TSA)

时域同步平均法(TSA)在时域上对信号进行同步平均(本质是一种等相位平均算法), 平均的过程使得“感兴趣”的频率成分得以增强, 而与转速无关的成分被削弱, 能够抑制或者消除无用的干扰噪声成分, 从而达到增强有用成分的目的。代士超等^[28]基于包络信号角域加窗同步平均, 克服行星齿轮箱故障时变传递路径及非平稳性, 有效提取了故障特征。对于转速恒定的信号, 要求某个轴在不同时刻采集的信号起始点相位保持一致, 所以, 该方法既要采集被测对象的信号, 还要记录旋转轴的时标信号。实际上, 旋转轴的转速不可能保持不变, 因此, 部分学者对模型进行了修正, 提出了对变周期信号同样有效的时域同步平均新算法, 能消除转速波动对降噪效果的影响。如 Mishra 等^[29]给出一种基于小波降噪角同步平均的变速滚动轴承故障诊断方法。时域同步平均方法应用到轴承故障诊断中, 可以减小背景噪声, 增强轴承故障状态特征, 但对强噪声干扰的轴承早期故障, 其对背景噪声的减少有限。

3.5 经验模态分解法(Empirical Mode Decomposition, EMD)

经验模态分解法(EMD)是 Huang 等引入 Hilbert 谱的概念提出的一种新的时频域信号分析法, EMD 基于信号局部特征时间尺度, 将复杂观测信号分解为若干本征模式函数(Intrinsic Mode Function, IMF)之和, 且可对 IMF 提取原始信号的特征信息。重庆大学的 Li 等^[30]改进全集经验模态分解结合 SVM, 有效进行了滚动轴承故障诊断。贾志明^[31]进行了轴承早期故障经验模态分解预警研究。武汉科技大学的 Yuan 等^[32]通过自适应投影本征变换的多变量经验模态分解和高阶奇异值分解用于轴承多故障诊断。经验模态分解具有自适应时频局部化、完备、正交的分解特点, 从根本上摆脱了传统傅里叶变换的局限性, 适合分解非平稳和非线性混合信号, 但其存在包络、端点效应和模态混叠等诸多理论和算法方

面的问题。

3.6 变分模态分解法(Variational Mode Decomposition, VMD)

变分模态分解法(VMD)能将信号的分解过程转化为变分问题求解, 可将信号分解为多个具有一定带宽和中心频率的模态分量, 能够克服经验模态分解的模态混叠及集成经验模态分解的时频聚集性不高等问题, 近年来得到广泛的应用。吕明珠等^[33]采用自适应变分模态分解使有效模态分量和噪声模态分量进行分离, 并通过重构信号的包络谱噪比实现了轴承早期退化起始点的检测。王恒迪等^[34]采用天牛须搜索算法优化搜索 VMD 的最佳参数组合并进行了轴承早期故障特征的提取。刘尚坤等^[35]采用最小熵解卷积和变分模态分解结合进行了轴承早期故障特征提取。但是, 该方法需要预先确定分解层数和二次惩罚因子等参数, 需要使用其他优化算法对分解层数进行和惩罚因子进行自适应获取, 一旦设置好较优的分解层数, 特征提取的效果将会很好。因此, 近年来该方法得到了较多的研究和关注。

3.7 盲源分离法(Blind Source Separation, BSS)

盲源分离是在源信号及其混合过程未知的情况下, 仅根据某些统计特性从观测信号中分离或恢复出源信号的过程。目前, 盲源分离包括 3 大主流算法: 独立成分分析法(Independent Component Analysis, ICA)、非负矩阵分解法(Nonnegative Matrix Factorization, NMF)和稀疏成分分析法(Sparse Component Analysis, SCA)。王奉涛等^[36]提出了基于流形学习的方法解决轴承故障信号的欠定盲源分离及最优观测信号的确定准则。刘鲲鹏等^[37]提出了扩展确定性随机分离法, 有效解决了变转速下轴承信号的盲源分离。Li 等^[38]提出了低阶稀疏分解方法, 对轴承振动信号进行盲源分离。刘嘉辉等^[39]结合盲源分离技术和全矢谱技术的各自优势, 提出了一种同源双通道信噪盲源分离法, 有效实现了轴承的故障诊断。独立成分分析要求混合矩阵从数学的角度为满秩, 源信号非高斯且相互独立; 非负矩阵分解中信源之间可以统计相关且可以为高斯分布, 但要求信源信号和混合矩阵非负。基于稀疏表示的盲源信号分离方法, 采用稀疏分析工具对信号进行稀疏表示和稀疏分解, 充分利用了信号的稀疏特性与结构特性, 具有较好的分离效果, 极大地推动了盲源信号分离的发展, 特别对于微小成分的提取更加有效。

3.8 小结

传统微小监测信号增强法在满足信号源独立、噪声分布模型已知等前提下能取得较好的效果。然

而,轴承所处的大型复杂装备系统结构复杂,构成设备的各部件之间相互联系、紧密耦合,给轴承微小监测信号获取问题提出了新的挑战。在混合系统结构未知情况下,盲源信号分离方法可根据监测信号的统计特性,克服系统未知扰动和强噪声的影响,从观测信号中将微小监测信号分离出来,是轴承实现微小监测信号获取并提取特征的有效技术。

4 轴承监测数据的融合表示技术

为捕获轴承运行状态上的微小变化,实际工程中通常会采用尽可能多的传感器获取轴承多种运行状态信息,对轴承进行多参数监测^{[9]513}。但直接获取的多参数监测信号很难准确、全面地反映轴承的实际运行状态。信息融合方法能够有效地综合各传感器间的相关、互补、冗余信息,提升轴承监测数据的数据质量,获取轴承的运行状态。因此,如何进行多参数监测数据融合表示,进而获取轴承运行状态准确、可靠、完备的描述,是轴承早期故障诊断的关键。目前典型的信息融合方法:卡尔曼滤波法、贝叶斯估计法、神经网络法、D-S证据推理、粒计算等。

4.1 卡尔曼滤波(Kalman Filtering)

卡尔曼滤波测量模型能对多传感器信息进行递推估计,实现动态实时融合表示。Oliveira等^[40]采用扩展卡尔曼滤波器从轴承噪声振动中实时识别了流体动压轴承早期缺油故障;赵靖等^[41]用基于负熵和无迹卡尔曼滤波的动态贝叶斯小波变换法实现了轴承微弱故障特征的提取;Cui等^[42]针对每种轴承运行状态建立了相应的状态空间模型,并将无迹卡尔曼滤波(Unscented Kalman Filter, UKF)算法引入到贝叶斯估计,计算每种状态每时刻的概率,通过检测加速降解阶段进行了轴承剩余使用寿命预测;Zou等^[43]提出了一种将转子有限元模型与增广卡尔曼滤波算法相结合的转子-轴承系统不平衡载荷识别方法,提高了不平衡量估计的精度。Shrivastava等^[44]利用卡尔曼滤波和基于递推最小二乘法的输入力估计转子中的单平面不平衡参数(振幅和相位角),给出了包括位移、速度和旋转响应在内的不同测量集的结果;朱光耀等^[45]利用经过滤波的线圈电压和控制器的输入作为计算转子位置和速度估算值的输入信号,估算值通过检测输入和输出数据进行模拟,成功估算了磁轴承的偏心位移值。当传感器的误差与系统符合高斯白噪声模型以及系统具有线性动力学模型时,卡尔曼滤波能够提供唯一的且最优的估计值,实时性能好,适合于不确定性信息的融合;但该方法仅能处理线性问题,且观测度不高,易发散。

该方法在轴承早期故障数据融合表示中还未见有报道,原因在于目前的轴承早期故障诊断多是基于单一参数进行诊断。

4.2 贝叶斯估计(Bayesian Estimation)

贝叶斯估计通过概率原则对传感器信息进行组合,对测量中的不确定信息使用条件概率进行融合表示。王进花等^[46]用证据下限派生类函数 Trace-Graph ELBO 进行随机变分推理,在发电机轴承故障样本数据量较少的情况下对轴承进行了故障诊断。张烁等^[47]提出了一种参数优化字典的结构化贝叶斯稀疏表示方法,有效降低了航空发动机背景噪声和杂质频率的干扰。Chen等^[48]利用贝叶斯神经网络的贝叶斯优化来推断形式规范的结构和参数,以频率时序逻辑的语义给出了故障的解释,可以获得较高的轴承故障诊断精度。于军等^[49]针对流向图分类推理能力较弱、计算成本较高的问题,提出了一种基于流向图和非朴素贝叶斯推理的滚柱轴承故障识别方法。毛文贵等^[50]针对轴承转子系统不平衡量识别过程中的采样效率,提出了基于遗传智能采样技术改进贝叶斯理论。Wang等^[51]提出基于高斯-厄米特积分的贝叶斯推理方法来估计小波参数的后验分布,用最优小波滤波提取轴承故障特征,从而识别局部轴承故障。贝叶斯概率框架下的信息融合方法适用于处理不确定、不一致信息的融合,但其较难适应高维或超高维数据的处理。

4.3 神经网络(Neural Network, NN)

神经网络通过指定的自学习算法,获取知识来得到不确定推理机制,利用神经网络自动推理以及信号处理的功能,实现多传感器的不确定性信息融合。Hu等^[52]将轴承时域信号转换为图像信号,通过非线性卷积层组合结合全局平均池层,优化相应的无线网络结构,实现了滚动轴承故障特征的自适应提取和故障诊断。Zhang等^[53]提出了一种基于联邦学习(Federated Learning, FL)和卷积神经网络(Convolutional Neural Network, CNN)的故障诊断方法,解决了不同的工业参与者在不同本地数据的情况下协作训练全局故障诊断模型。Xue等^[54]在提出的1D-CNN和2D-CNN并行多通道结构中提取深度特征,通过特征融合进行连接,建立了双流特征融合卷积神经网络(Two-Stream Feature Fusion Convolutional Neural Network, TSFFCNN),获得了轴承更可靠的诊断效果。Bai等^[55]给出了一种基于多通道卷积神经网络(Multi-channel Convolutional Neural Network, MCNN)和多尺度限幅融合(Multi-scale Clipping Fusion, MSCF)数据增强技术的滚动轴承故障诊断新策

略。杨洁等^[56]采用一维卷积神经网络(One-Dimensional Convolutional Neural Network, 1D-CNN)对航空发动机轴承4个加速度传感器故障振动数据进行特征融合、提取与分类,故障诊断准确率得到大幅提升。王廷轩等^[57]基于连续小波变换(Continuous Wavelet Transform, CWT)算法与迁移学习(Transfer Learning, TL)算法相融合进行滚动轴承故障诊断,提高了不同工况下跨平台的滚动轴承故障诊断精度和鲁棒性。王永坚等^[58]运用神经网络和D-S证据理论对尾轴承磨损故障进行融合诊断,依据各方法的标准磨损界限值,将各检测原始数据预处理转换为布尔值,运用神经网络获取每种方法的故障域单项诊断结果,并通过具体的案例验证了方法的准确性。目前,神经网络融合方法已经逐步发展为深度网络的融合,融合效果比浅层网络更好,但基于深度神经网络的轴承检测数据融合方法依然会存在过拟合和泛化性等问题。

4.4 D-S 证据推理 (Dempster-Shafer Evidence Theory)

D-S 证据推理是利用 Dempster 合成规则将各个证据体合并成一个新的证据体,采用不确定区间和概率区间决定多证据体中假设似然函数,在此基础上进行推理和融合。张钢等^[59]提出了一种基于改进 D-S 证据理论的信息融合诊断框架的滚动轴承机械故障诊断方法,能够有效提高证据可信度,降低不确定性。刘建强等^[60]提出了一种新的均值加权融合法对经典证据融合算法进行改进,提取轴承振动信号的特征频率谱峰比值与频率均值,设置对应的概率分配函数来分配其对不同元素的支持度,并进行证据融合。Hui 等^[61]提出了一种新的 SVM-DS 模型来解决每个 SVM 模型产生的冲突结果,从而提高了轴承多故障分类精度。D-S 证据理论适用于处理不确定、不精确、不完全信息的融合,但是不能处理不一致信息;随着鉴别元素的增加,其组合计算复杂度呈指数增长。

4.5 粒计算(Granular Computing, GrC)

粒计算方法通过选取与轴承诊断任务相适应的粒度空间,在不同划分空间上进行粒度转换和求解,实现对海量多模态、不确定、非精确信息的融合表示。Lu 等^[62]提出了一种基于粒度计算和回声状态网络的故障诊断模型,并对制导雷达信号处理模块的故障诊断进行了验证。胡小曼等^[63]用改进经验模态分解结合小波包去噪,提取信号多种特征进行主成分分析,将其模糊信息粒化处理,用改进粒子群算法优化相关向量机模型,对剩余寿命进行了预测。葛红平等^[64]提出了一种将模糊信息粒化、幅值感知

排列熵和鲸鱼优化支持向量机相结合,进行滚动轴承智能故障诊断的方法。陈法法等^[65]通过提取轴承各振动信号的特征指标并进行模糊信息粒化,进而提取有效分量信息;通过小波支持向量机对各指标分量退化趋势及波动范围进行了预测。粒计算是粗糙集、模糊集、词计算、商空间及区间计算等理论的超集,能够有效地解决不精确、不完整、模糊以及海量信息等问题,适应于轴承早期故障诊断任务中的变粒度需求。

4.6 小结

传统方法能对多源异构信息的不完善性进行融合,并建立其广适性多源异构信息融合模型。然而,轴承早期故障需要监测信号种类较多、差异大、数量多、维度高、数据量大并呈现分布式、多层次混杂特性,传统方法不能完全适用于轴承振动、温度、力矩、润滑、声发射及转速等较多参数的融合表示。粒计算的粒度范式与监测数据的多层次特性高度契合,粒计算整合了模糊信息粒化、粗糙集和区间计算等理论,能通过选取与早期故障诊断任务相适应的粒度空间,建立广适的多粒度信息融合分析模型,对监测数据规模进行压缩,克服轴承多种信号监测数据的高维度、大数据量、不确定、模糊特性的融合表示问题,是准确、全面描述轴承早期状态的重要思路。

5 轴承早期故障智能诊断技术

传统基于信号处理的轴承故障诊断方法需要诊断者具备一定的专业知识,提取故障特征,才能进行正确的判断,也形成了相对完整的理论体系。但在轴承的早期故障阶段,故障特征微小;多工况交替的作业过程导致运行状态和早期故障特征呈强非线性关系;装备部件间存在多重混叠,致使早期故障难以识别。轴承早期故障诊断的核心是如何利用其不同来源和类型的当前及历史状态大量无标签数据及部分有标签数据,使用智能方法提取、表征及识别数据中隐含的故障特征。智能故障诊断能够自主学习挖掘潜藏的本征故障信息,自动评价与识别轴承状态,不需要专家进行分析和解释,从而更好地服务于工程应用。现有的智能故障诊断方法包括浅层智能诊断模型(人工神经网络、支持向量机、模糊推理与极限学习机等)和深度智能诊断模型(深度学习和深度迁移学习方法)。

5.1 人工神经网络方法(Artificial Neural Network, ANN)

人工神经网络方法(ANN)具有自学习、非线性映射、联想存储和并行分布式处理功能,适合于多

征兆的复杂识别问题,其用于轴承故障诊断主要有以下3种方式:从模式识别角度应用神经网络作为分类器进行故障诊断;从预测角度应用神经网络作为动态预测模型进行故障预测;从知识处理角度建立基于神经网络的诊断专家系统。近几年发表的文献表明,在基于ANN的轴承故障诊断方面,Ewert等^[66]进行了较深入的研究。虽然神经网络可以根据需求设置网络结构,以任意精度逼近非线性函数,但是,网络的学习需要大量的故障样本,故在用于无法获得大量工业过程故障数据的轴承时受到一定的限制;同时,在实际应用中受限于复杂度的影响,也只是设置2~3个隐层,降低了逼近的精度;进一步,如何确保故障样本的完整性和典型性以及该方法的收敛性、训练速度和诊断的实时性等,都是制约基于ANN的轴承早期故障诊断技术发展的瓶颈。

5.2 支持向量机方法(Support Vector Machine, SVM)

支持向量机方法(SVM)是在有限样本统计学习理论和风险最小原理基础上发展起来的一种新的机器学习方法。支持向量机具有全局最优解、较强的学习能力、完善的理论基础及很好的泛化能力,特别适用于小样本学习,能很好地解决有限数量非线性样本的高维模型构造问题。印度空间科学技术研究院采用基于改进小波互谱技术和支持向量机进行了滚动轴承健康监测^[67]。Wang等^[68]提出了复杂信号滚动轴承故障诊断的改进多尺度加权置换熵优化支持向量机方法。此外,本文作者针对滚动轴承异常辨识问题,提出了一种混沌分形特征与支持向量数据域描述的异常检测方法^[69]。基于SVM的轴承故障诊断的不足之处是诊断精度与故障样本的完备性和代表性有很大关系,只是从分类的角度对故障进行诊断,并没有深层次地追求数据的结构信息。2013—2016年间,多采用支持向量机和神经网络的方法进行轴承故障诊断。

5.3 模糊推理(Fuzzy Reasoning)与极限学习机(Extreme Learning Machine, ELM)等

模糊推理能弥补神经网络无法处理逻辑推理过程和定性知识的缺点,但模糊推理缺少数值的校正和定量分析,一般将该方法与其他智能算法相结合能获得更好的应用效果^[70];从函数逼近论的角度分析,极限学习机采用的是点点逼近的1阶多项式逼近模式,没有有效表征逼近的光滑性程度,故难以得到相邻点间信号特征的线性组合,因而,该方法进行轴承故障诊断时会忽视信号相邻点之间的相关性信息。除此之外,隐马尔可夫模型、粗糙集、随机

森林等方法也被用于轴承智能故障诊断。目前,通过多个分类器的组合来提升故障诊断准确性的方法是研究的一个重要方向^[71]。其中, Freund提出的 Adaboost算法是将众多简单的分类器有效结合起来,以达到更好的分类效果的一种方法^[72]。但该方法也没有深层次地追求数据的结构信息,只是从分类的角度对故障进行诊断识别。

5.4 深度学习方法(Deep Learning)

深度学习近似一个高度复杂的非线性特征提取器,每个隐层从输入数据中学习获取高阶相关性特征,为解决深层结构相关的优化难题带来了希望,并且可以不依赖测试变量的历史数据,能达到实时在线诊断的目的,这对工业系统中故障的检测具有较强的实用价值,在处理数据结构高度复杂的大数据方面表现优异^[73-74]。国内对深度学习的研究现处于兴盛阶段,但已发表的文献多是侧重于应用领域。针对轴承故障诊断的研究文献从2016年才有报道。向宙等^[75-79]发表的文献均采用深度学习相关方法进行轴承故障诊断,取得了较好的识别效果。但是,针对轴承早期故障特征挖掘的研究报道较少,现仅见到3篇文献进行了相关研究:石怀涛等^[80]采用 SW-DAE-LSTM模型(堆叠去噪自编码器-长短期记忆)进行训练,利用模型的预测值与真实值的残差检测轴承早期故障;施文锐^[81]将受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)与自编码器(Auto Encoder, AE)算法模型与迁移学习思想结合,用轴承故障公开数据集训练样本,以实验采集的数据作为测试样本进行轴承早期故障诊断;张继旺等^[82]提出了一种基于变分模态分解与卷积神经网络的轴承早期故障特征挖掘及智能诊断方法。这3篇文献均未真正地对早期故障进行诊断,只是对微小故障进行了有效识别。但是,基于深度学习的方法将孤立的特征提取和分类模型有机整合,通过构建深层网络对状态数据进行抽象表达,建立微小故障特征与故障模式之间的复杂映射关系,是实现轴承早期故障诊断的重要思路。2016年以来,采用深度学习方法进行轴承故障诊断和预测方面已经取得了部分较好的成果。但仍然存在很大的改进空间:①在实际工业现场往往很少产生早期故障,因此,难于获取大量的有标签故障数据^{[12]97},而深度学习模型中随着隐层数的增加,可训练的参数量呈指数级增加,训练模型所需要的有标签数据量、算力和时间开销巨大。②目前大多数的文献中使用的都是不超过5个隐层的模型^[83],原因在于使用更深层的模型对小样本数据集训练,会出现过拟合的现象,导致其泛化能力

下降,使得在真实工业环境中的诊断准确率降低。③深度学习模型的选择和设计(超参数、学习率和丢弃率等)对训练时间和模型性能有明显的影响。

5.5 深度迁移学习方法(Deep Transfer Learning)

迁移学习能使一个预训练模型的强大技能被重新迁移到相关的问题上,可以解决深度学习故障表示不充分、误报率高、训练样本不足、训练耗时长、轴承故障在线检测困难等问题。自2017年开始,基于迁移学习的轴承故障诊断方面的研究文献已有40余篇。如文献[84-90]都是最近几年针对轴承故障诊断方面的最新成果。这些成果针对变工况条件下很难或无法获取大量带标签的振动数据问题,采用迁移学习取得了很好的成果。但现有针对轴承故障的迁移学习方法,仍需在某一轴承故障数据集上从头训练深度学习模型,训练和优化深度学习模型的时间消耗仍然很大。而轴承有标签故障数据集的大小限制了更深层深度迁移学习模型的应用。针对轴承早期故障诊断问题,目前仅见到1篇文献报道。毛文涛等^[91]从时序异常检测的角度,提出了一种面向多域迁移的深度自编码网络轴承早期故障在线检测方法,在XJTU-SY数据集上的实验验证了该方法具有更好的早期故障检测实时性和更低的误报警数。但是,该方法仍需要采集轴承大量离线正常状态样本数据进行学习和训练,并且阈值的设置也需要因环境的改变而重新设置,不具有普适性。但可以预见,迁移学习方法将是解决轴承早期故障诊断问题的利器。

5.6 小结

在轴承智能故障诊断中,判断故障是否发生的关键仍然属于基于“征兆”的故障诊断模式,即寻找到相应的故障征兆后,再通过分类算法评估是否发生故障。浅层诊断模型要求样本准确、完备,否则,诊断准确率很难有大的提升。依据函数逼近理论的思想,如果特征提取得足够完备,即能采用精度足够高的高阶多项式对故障特征进行合理表征,并刻画数据中隐含的细节性潜在微小故障信息,从而更准确判别轴承的运行状态。自2016年以来,深度学习诊断轴承早期故障已经取得了部分较好的成果,但现有在高性能指标(高稳定和高可靠性)约束下所设计的轴承,在现实中已充分考虑了故障寿命程度,使其在运行中所发生的故障越来越少,难以获取带标签的早期微小故障低信噪比信号,影响深度学习模型的训练,所获取的数据通过深度学习对轴承运行状况的解释能力还有待实际验证。而深度迁移学习可以通过离线数据进行模型训练,自动组

合低层特征,形成更加抽象的高阶自相关性高层、分布式特征表示,训练好的模型可以迁移到工业现场进行变工况情况下在线性能评估,是实现轴承早期在线故障诊断的新发展方向,有巨大的应用前景。

6 结论与展望

根据对数据驱动的轴承早期故障诊断难点的分析及对相关技术现状进行综述,目前有3个方面及相关技术值得开展更深入的研究:

(1)在微小监测信号增强方面,盲源分离在源信号及其混合过程未知情况下,可有效克服系统未知扰动和强噪声的干扰,根据源信号的统计特性,由观测信号恢复源微小监测信号。是解决轴承故障征兆信号微弱、征兆信息难获取等问题的有效技术。

(2)在轴承运行状态描述层面,粒计算通过选择与早期诊断任务相适应的粒度计算空间,对监测参数规模进行压缩,能很好地克服轴承监测参数的高维特性,有效地解决不精确、不完整、模糊及海量信息的融合表示。是解决轴承运行监测数据较多,运行状态难描述问题的重要思路。

(3)早期故障的诊断识别技术。深度迁移学习模型通过轴承离线运行工况下部分有标签及海量无标签数据训练深层网络,可挖掘潜藏在状态数据内部的不显著、关联性、深层次故障定量特征,并自动建立特征与早期故障模式间的映射关系。训练好模型后,可以迁移到轴承变工况下早期故障的实时精细识别,是解决故障特征可分性弱、早期故障难诊断等新的发展方向,有望获得创新性和实用性的成果。

参 考 文 献

- [1] 张俊鹏,杨志勃,陈雪峰,等.卷积神经网络在轴承故障诊断中的可解释性探讨[J].轴承,2020(7):54-60.
ZHANG Junpeng, YANG Zhibo, CHEN Xuefeng, et al. Interpretability discussion on convolutional neural network in bearing fault diagnosis[J]. Bearing, 2020(7): 54-60.
- [2] 王江萍.机械设备故障诊断技术及应用[M].西安:西北工业大学出版社,2000:1-21.
WANG Jiangping. Fault diagnosis technology and application of mechanical equipment [M]. Xi'an: Northwest University of Technology Press, 2000: 1-21.
- [3] 尉询楷,冯悦,杨立,等.航空发动机中介主轴承故障预测研究[C]//航空安全与装备维修技术学术研讨会论文集.北京:国防工业出版社,2014:10.
WEI Xunkai, FENG Yue, YANG Li, et al. Research on fault prediction of aeroengine intermediate main bearing [C]//Proceedings of the Symposium on Aviation Safety and Equipment Maintenance Technology. Beijing: National Defense Industry Press, 2014: 10.
- [4] 王浩,郭兰中,林化清,等.常幅载荷下滑轨与滚轮寿命及可靠性

- 研究[J].轴承,2016(10):36-39.
WANG Hao, GUO Lanzhong, LIN Huaqing, et al. Research on life of sliding rail and idler wheel and reliability under constant amplitude load[J]. Bearing, 2016(10):36-39.
- [5] LIU Z P, ZHANG L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings [J]. Measurement, 2020, 149(C): 107002.
- [6] 孟晨, 杨华晖, 王成, 等. 数据驱动的武器系统电子元件级故障诊断研究综述[J]. 系统工程与电子技术, 2021, 43(2): 574-583.
MENG Chen, YANG Huahui, WANG Cheng, et al. Review on data-driven fault diagnosis for electronic components and units level of weapon system [J]. Systems Engineering and Electronics, 2021, 43(2): 574-583.
- [7] HU Y X, LIN J H, TAN A C. Failure analysis of gearbox in CRH high-speed train [J]. Engineering Failure Analysis, 2019, 105: 110-126.
- [8] SOUALHI M, KHANH N, SOUALHI A, et al. Health monitoring of bearing and gear faults by using a new health indicator extracted from current signals[J]. Measurement, 2019, 141: 37-51.
- [9] 陈金海, 李伟, 张文远, 等. 智能滚动轴承监测方法与技术研究现状综述[J]. 机械强度, 2021, 43(3): 509-516.
CHEN Jinhai, LI Wei, ZHANG Wenyuan, et al. Research status of smart rolling bearing monitoring methods [J]. Journal of Mechanical Strength, 2021, 43(3): 509-516.
- [10] 李娟, 周东华, 司小胜, 等. 微小故障诊断方法综述[J]. 控制理论与应用, 2012, 29(12): 1517-1529.
LI Juan, ZHOU Donghua, SI Xiaosheng, et al. Review of incipient fault diagnosis methods [J]. Control Theory & Applications, 2012, 29(12): 1517-1529.
- [11] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.
WEN Chenglin, LÜ Feiya, BAO Zhejing, et al. A review of data driven-based incipient fault diagnosis [J]. Acta Automatica Sinica, 2016, 42(9): 1285-1299.
- [12] 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 Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [13] 张可, 周东华, 柴毅. 复合故障诊断技术综述[J]. 控制理论与应用, 2015, 32(9): 1143-1157.
ZHANG Ke, ZHOU Donghua, CHAI Yi. Review of multiple fault diagnosis methods [J]. Control Theory & Applications, 2015, 32(9): 1143-1157.
- [14] 陈是扞, 彭志科, 周鹏. 信号分解及其在机械故障诊断中的应用研究综述[J]. 机械工程学报, 2020, 56(17): 91-107.
CHEN Shiqian, PENG Zhike, ZHOU Peng. Review of signal decomposition theory and its applications in machine fault diagnosis [J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107.
- [15] FACKRELL J W A, WHITE P R, HAMMOND J K, et al. The interpretation of the bispectra of vibration signals-I [J]. Theory, Mechanical System and Signal Processing, 1995: 257-266.
- [16] FACKRELL J W A, WHITE P R, HAMMOND J K, et al. The interpretation of the bispectra of vibration signals-II [J]. Theory, Mechanical System and Signal Processing, 1995: 257-266.
- [17] DONG G, CHEN J, ZHAO F G. A frequency-shifted bispectrum for rolling element bearing diagnosis [J]. Journal of Sound and Vibration, 2015, 339(17): 396-418.
- [18] 程静, 王维庆, 樊小朝, 等. 基于二值双谱和模糊聚类的风电轴承故障诊断[J]. 振动、测试与诊断, 2018, 38(4): 765-771.
CHENG Jing, WANG Weiqing, FAN Xiaochao, et al. Bearing fault pattern recognition of wind turbine based on two-value bispectrum feature-fuzzy clustering method [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(4): 765-771.
- [19] WANG G B, GU F S, IBRAHIM R, et al. A sparse modulation signal bispectrum analysis method for rolling element bearing diagnosis [J]. Mathematical Problems in Engineering, 2018, 2018: 1-12.
- [20] 张锐戈, 肖荣辉, 高忠坚. 变工况下滚动轴承双谱分析及智能故障诊断[J]. 噪声与振动控制, 2021, 41(6): 97-104.
ZHANG Ruige, XIAO Ronghui, GAO Zhongjian. Bispectrum analysis and intelligent fault diagnosis for rolling element bearings under variable operation conditions [J]. Noise and Vibration Control, 2021, 41(6): 97-104.
- [21] BENZI R, SUTERA A, VULPIANI A. The mechanism of stochastic resonance [J]. Journal of Physics a General Physics, 1981, 14(11): L453-L457.
- [22] LIU Z W, XIAO L, BAO J S, et al. Bearing incipient fault detection method based on stochastic resonance with triple-well potential system [J]. Journal of Shanghai Jiaotong University (Science), 2020, 2: 1-6.
- [23] ZHANG G, WANG H, ZHANG T Q. Stochastic resonance of coupled time-delayed system with fluctuation of mass and frequency and its application in bearing fault diagnosis [J]. Journal of Central South University, 2021, 28(9): 2931-2946.
- [24] ZHANG C, DUAN H, XUE Y, et al. The enhancement of weak bearing fault signatures by stochastic resonance with a novel potential function [J]. Energies, 2020, 13(23): 1-15.
- [25] 乔志城, 刘永强, 廖英英. 改进经验小波变换与最小熵解卷积在铁路轴承故障诊断中的应用[J]. 振动与冲击, 2021, 40(2): 81-90.
QIAO Zhicheng, LIU Yongqiang, LIAO Yingying. Application of improved wavelet transform and minimum entropy deconvolution in railway bearing fault diagnosis [J]. Journal of Vibration and Shock, 2021, 40(2): 81-90.
- [26] 郑近德, 潘海洋, 戚晓利, 等. 基于改进经验小波变换的时频分析方法及其在滚动轴承故障诊断中的应用[J]. 电子学报, 2018, 46(2): 358-364.
ZHENG Jinde, PAN Haiyang, QI Xiaoli, et al. Enhanced empirical wavelet transform based time-frequency analysis and its application to rolling bearing fault diagnosis [J]. Acta Electronica Sinica, 2018, 46(2): 358-364.
- [27] WAN S T, PENG B. Adaptive asymmetric real Laplace wavelet filtering and its application on rolling bearing early fault diagnosis [J]. Shock and Vibration, 2019(20): 1-20.
- [28] 代士超, 郭瑜, 伍星. 基于同步平均与倒频谱编辑的齿轮箱滚动轴承故障特征量提取[J]. 振动与冲击, 2015, 34(21): 205-209.
DAI Shichao, GUO Yu, WU Xing. Gearbox rolling bearings' fault features extraction based on cepstrum editing and time domain synchronous average [J]. Journal of Vibration and Shock, 2015, 34(21): 205-209.

- [29] MISHRA C, SAMANTARAY A K, CHAKRABORTY G. Rolling element bearing fault diagnosis under slow speed operation using wavelet denoising[J]. *Measurement*, 2017, 103: 77–86.
- [30] LI R, RAN C, ZHANG B, et al. Rolling bearings fault diagnosis based on improved complete ensemble empirical mode decomposition with adaptive noise, nonlinear entropy, and ensemble SVM[J]. *Applied Sciences*, 2020, 10(16): 1210–1218.
- [31] 贾志明, 梁伟, 俞徐超. 基于经验模态分解的滚动轴承早期故障预警研究[J]. *设备管理与维修*, 2016(S2): 31–34.
JIA Zhiming, LIANG Wei, YU Xuchao. Research on early fault early warning of rolling bearing based on empirical mode decomposition[J]. *Plant Maintenance Engineering*, 2016(S2): 31–34.
- [32] YUAN R, LÜ Y, SONG G B. Multi-fault diagnosis of rolling bearings via adaptive projection intrinsically transformed multivariate empirical mode decomposition and high order singular value decomposition[J]. *Sensors (Basel, Switzerland)*, 2018, 18(4): 1210–1218.
- [33] 吕明珠, 刘世勋, 苏晓明, 等. 基于自适应变分模态分解和包络谱噪比的滚动轴承早期退化检测[J]. *振动与冲击*, 2021, 40(13): 271–280.
LÜ Mingzhu, LIU Shixun, SU Xiaoming, et al. Early degradation detection of rolling bearing based on adaptive variational mode decomposition and envelope harmonic to noise ratio[J]. *Journal of Vibration and Shock*, 2021, 40(13): 271–280.
- [34] 王恒迪, 邓四二, 杨建玺, 等. 基于参数优化变分模态分解的滚动轴承早期故障诊断[J]. *振动与冲击*, 2020, 39(23): 38–46.
WANG Hengdi, DENG Sier, YANG Jianxi, et al. Incipient fault diagnosis of rolling bearing based on VMD with parameters optimized[J]. *Journal of Vibration and Shock*, 2020, 39(23): 38–46.
- [35] 刘尚坤, 唐贵基, 王晓龙. 基于MED和变分模态分解的滚动轴承早期故障诊断方法[J]. *机械传动*, 2017, 41(9): 179–182.
LIU Shangkun, TANG Guiji, WANG Xiaolong. Incipient fault diagnosis method for rolling bearing based on MED and variational mode decomposition[J]. *Journal of Mechanical Transmission*, 2017, 41(9): 179–182.
- [36] 王奉涛, 薛宇航, 王雷, 等. 基于流形学习的滚动轴承故障盲源分离方法[J]. *振动、测试与诊断*, 2020, 40(1): 43–47.
WANG Fengtao, XUE Yuhang, WANG Lei, et al. Blind source separation method for rolling bearing faults based on manifold learning[J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(1): 43–47.
- [37] 刘鲲鹏, 夏均忠, 白云川, 等. EDRS在滚动轴承振动信号盲源分离中的应用[J]. *振动与冲击*, 2019, 38(20): 106–111.
LIU Kunpeng, XIA Junzhong, BAI Yunchuan, et al. Application of EDRS in blind source separation of rolling element bearing vibration signal[J]. *Journal of Vibration and Shock*, 2019, 38(20): 106–111.
- [38] LI G Z, TANG G, WANG H Q, et al. Blind source separation of composite bearing vibration signals with low-rank and sparse decomposition[J]. *Measurement*, 2019, 145: 323–334.
- [39] 刘嘉辉, 董辛旻, 李剑飞. 基于全矢谱时间固有尺度分解和独立分量分析盲源分离降噪的滚动轴承故障特征提取[J]. *中国机械工程*, 2018, 29(8): 943–948.
LIU Jiahui, DONG Xinmin, LI Jianfei. Fault feature extraction of rolling bearing based on noises reduced by full vector spectrum ITD-ICA blind source separation[J]. *China Mechanical Engineering*, 2018, 29(8): 943–948.
- [40] OLIVEIRA M V M, FIORAVANTI A, DANIEL G B. Identification of oil starvation in hydrodynamic journal bearing using rotor vibration and extended Kalman filter[J]. *Tribology International*, 2022, 169: 1–11.
- [41] 赵靖, 廖英英, 杨绍普, 等. 基于无迹卡尔曼滤波的动态贝叶斯小波变换在轴承故障诊断中的应用[J]. *振动与冲击*, 2020, 39(11): 53–62.
ZHAO Jing, LIAO Yingying, YANG Shaopu, et al. An extension of unscented Kalman filter to dynamic Bayesian wavelet transform in fault diagnosis of rolling element bearings[J]. *Journal of Vibration and Shock*, 2020, 39(11): 53–62.
- [42] CUI L, WANG X, XU Y G, et al. A novel switching unscented Kalman filter method for remaining useful life prediction of rolling bearing[J]. *Measurement*, 2018, 135: 678–684.
- [43] ZOU D L, ZHAO H, LIU G Y, et al. Application of augmented Kalman filter to identify unbalance load of rotor-bearing system: theory and experiment[J]. *Journal of Sound and Vibration*, 2019, 463(C): 114972.
- [44] SHRIVASTAVA A, MOHANTY A R. Estimation of single plane unbalance parameters of a rotor-bearing system using Kalman filtering based force estimation technique[J]. *Journal of Sound Vibration*, 2018, 418: 184–199.
- [45] 朱光耀, 李月洁. 基于卡尔曼滤波器的三极磁轴承位置自检测[J]. *控制工程*, 2016, 23(7): 1034–1038.
ZHU Guangyao, LI Yuejie. Self-sensing three-pole magnetic bearing using a Kalman filter[J]. *Control Engineering of China*, 2016, 23(7): 1034–1038.
- [46] 王进花, 岳亮辉, 曹洁, 等. 基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断[J/OL]. *控制与决策*, 2022-02-07 [2022-03-03]. <https://kns.cnki.net/kcms/detail/21.1124.tp.20220207.0909.017.html>.
WANG Jinhua, YUE Lianghui, CAO Jie, et al. Fault diagnosis of generator bearing based on stochastic variational inference Bayesian neural network[J/OL]. *Control and Decision*, 2022-02-07 [2022-03-03]. <https://kns.cnki.net/kcms/detail/21.1124.tp.20220207.0909.017.html>.
- [47] 张烁, 刘治汶. 航空发动机轴承故障结构化贝叶斯稀疏表示[J]. *航空学报*, 2022, 43(9): 172–183.
ZHANG Shuo, LIU Zhiwen. Structural Bayesian sparse representation of aero-engine bearing failures[J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(9): 172–183.
- [48] CHEN G, LIU M, CHEN J. Frequency-temporal-logic-based bearing fault diagnosis and fault interpretation using Bayesian optimization with Bayesian neural networks[J]. *Mechanical Systems and Signal Processing*, 2020, 145(C): 106951.
- [49] 于军, 刘立飞, 邓立为, 等. 基于流向图和非朴素贝叶斯推理的滚柱轴承故障程度识别[J]. *计算机集成制造系统*, 2020, 26(5): 1202–1210.
YU Jun, LIU Lifei, DENG Liwei, et al. Fault severity identification of roller bearing based on flow graph and NNBI[J]. *Computer Integrated Manufacturing Systems*, 2020, 26(5): 1202–1210.
- [50] 毛文贵, 李建华, 刘桂萍. 遗传智能采样技术的贝叶斯理论识别滑动轴承-转子系统不平衡量[J]. *振动工程学报*, 2019, 32(4): 660–667.
MAO Wengui, LI Jianhua, LIU Guiping. Bayesian theory using genet-

- ic intelligent sampling technique to identify the unbalance parameters of a sliding bearing-rotor system [J]. *Journal of Vibration Engineering*, 2019, 32(4): 660-667.
- [51] WANG D, TSUI K L, ZHOU Q. Novel Gauss-Hermite integration based Bayesian inference on optimal wavelet parameters for bearing fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2016, 72-73: 80-91.
- [52] HU J, DENG S E. Rolling bearing fault diagnosis based on wireless sensor network data fusion [J]. *Computer Communications*, 2022, 181: 404-411.
- [53] ZHANG Z, XU X, GONG W, et al. Efficient federated convolutional neural network with information fusion for rolling bearing fault diagnosis [J]. *Control Engineering Practice*, 2021, 116: 104913.
- [54] XUE F, ZHANG W, XUE F, et al. A novel intelligent fault diagnosis method of rolling bearing based on two-stream feature fusion convolutional neural network [J]. *Measurement*, 2021, 176: 109226.
- [55] BAI R X, XU Q S, MENG Z, et al. Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation [J]. *Measurement*, 2021, 184: 109885.
- [56] 杨洁, 王安平, 王景霖, 等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断 [J]. *中国电机工程学报*, 2022, 42(13): 4933-4942.
YANG Jie, WAN Anping, WANG Jinglin, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion [J]. *Proceedings of the CSEE*, 2022, 42(13): 4933-4942.
- [57] 王廷轩, 刘韬, 王振亚, 等. 融合迁移卷积神经网络的跨域滚动轴承故障诊断 [J]. *电子测量技术*, 2021, 44(10): 167-174.
WANG Tingxuan, LIU Tao, WANG Zhenya, et al. Cross-domain rolling bearing fault diagnosis based on convolutional neural network combined with transfer learning [J]. *Electronic Measurement Technology*, 2021, 44(10): 167-174.
- [58] 王永坚, 陈景锋, 杨小明. 神经网络和证据理论融合的尾轴承磨损故障诊断 [J]. *中国航海*, 2014, 37(4): 20-24.
WANG Yongjian, CHEN Jingfeng, YANG Xiaoming. Diagnosis of stern bearing wear fault with combination of neural network and evidence theory [J]. *Navigation of China*, 2014, 37(4): 20-24.
- [59] 张钢, 田福庆, 梁伟阁, 等. 基于改进D-S证据理论的滚动轴承故障诊断 [J]. *海军工程大学学报*, 2019, 31(4): 42-47.
ZHANG Gang, TIAN Fuqing, LIANG Weige, et al. Fault diagnosis rolling element bearing based on improved D-S evidence theory [J]. *Journal of Naval University of Engineering*, 2019, 31(4): 42-47.
- [60] 刘建强, 孙康茗, 赵东明, 等. 基于证据融合算法的地铁车辆轴承故障检测方法研究 [J]. *铁道学报*, 2019, 41(4): 55-63.
LIU Jianqiang, SUN Kangming, ZHAO Dongming, et al. Research on fault diagnosis method for bogie bearings of metro vehicle based on evidence fusion algorithm [J]. *Journal of the China Railway Society*, 2019, 41(4): 55-63.
- [61] HUI K H, LIM M H, LEONG M S, et al. Dempster-Shafer evidence theory for multi-bearing faults diagnosis [J]. *Engineering Applications of Artificial Intelligence*, 2017, 57: 160-170.
- [62] LU C, XU P, CONG L H. Fault diagnosis model based on granular computing and echo state network [J]. *Engineering Applications of Artificial Intelligence*, 2020, 94(1): 103694.
- [63] 胡小曼, 王艳, 纪志成. 模糊信息粒化与改进RVM的滚动轴承寿命预测 [J]. *系统仿真学报*, 2021, 33(11): 2561-2571.
HU Xiaoman, WANG Yan, JI Zhicheng. Fuzzy information granulation and improved RVM for rolling bearing life prediction [J]. *Journal of System Simulation*, 2021, 33(11): 2561-2571.
- [64] 葛红平, 刘晓波, 黄朝晖, 等. 粒化幅值感知排列熵和WOA-SVM的滚动轴承故障诊断 [J]. *噪声与振动控制*, 2021, 41(4): 101-108.
GE Hongping, LIU Xiaobo, HUANG Chaohui, et al. Fault diagnosis method of rolling bearings based on granulation amplitude aware permutation entropy and WOA-SVM [J]. *Noise and Vibration Control*, 2021, 41(4): 101-108.
- [65] 陈法法, 杨勇, 陈保家, 等. 基于模糊信息粒化与小波支持向量机的滚动轴承性能退化趋势预测 [J]. *中国机械工程*, 2016, 27(12): 1655-1661.
CHEN Fafa, YANG Yong, CHEN Baojia, et al. Degradation trend prediction of rolling bearings based on fuzzy information granulation and wavelet support vector machine [J]. *China Mechanical Engineering*, 2016, 27(12): 1655-1661.
- [66] EWERT P, ORLOWSKA-KOWALSKA T, JANKOWSKA K. Effectiveness analysis of PMSM motor rolling bearing fault detectors based on vibration analysis and shallow neural networks [J]. *Energies*, 2021, 14(3): 712-714.
- [67] ABHILASH S, PRADEEP R, REJITH R, et al. Health monitoring of rolling element bearings using improved wavelet cross spectrum technique and support vector machines [J]. *Tribology International*, 2016, 154: 106650-106661.
- [68] WANG Z, YAO L G, CHEN G, et al. Modified multiscale weighted permutation entropy and optimized support vector machine method for rolling bearing fault diagnosis with complex signals [J]. *ISA Transactions*, 2021, 85: 746-759.
- [69] 李兆飞, 柴毅, 任小洪. 混沌分形特征与支持向量数据域描述辨识机械动态系统异常 [J]. *农业工程学报*, 2015, 31(10): 211-218.
LI Zhaofei, CHAI Yi, REN Xiaohong. Abnormal identification method of dynamic systems based on support vector data description feature extraction for chaos fractal [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2015, 31(10): 211-218.
- [70] 陈洪转, 赵爱佳, 李腾蛟, 等. 基于故障树的复杂装备模糊贝叶斯网络推理故障诊断 [J]. *系统工程与电子技术*, 2021, 43(5): 1248-1261.
CHEN Hongzhuan, ZHAO Aijia, LI Tengjiao, et al. Fuzzy Bayesian network inference fault diagnosis of complex equipment based on fault tree [J]. *Systems Engineering and Electronics*, 2021, 43(5): 1248-1261.
- [71] ZHUO L, ZHANG X F, ZHANG L, et al. Motor fault diagnosis using attention mechanism and improved adaboost driven by multi-sensor information [J]. *Measurement*, 2021, 170: 108718.
- [72] CHEN F F, CHENG M T, TANG B P. Pattern recognition of a sensitive feature set based on the orthogonal neighborhood preserving embedding and adaboost_SVM algorithm for rolling bearing early fault diagnosis [J]. *Measurement Science and Technology*, 2020, 31(10): 105007-105015.
- [73] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域的研究现状与挑战 [J]. *控制与决策*, 2017, 32(8): 1345-1358.
REN Hao, QU Jianfeng, CHAI Yi, et al. Deep learning for fault diag-

- nosis: the state of the art and challenge [J]. Control and Decision, 2017, 32(8): 1345-1358.
- [74] 张西宁, 郭清林, 刘书语. 深度学习技术及其故障诊断应用分析与展望[J]. 西安交通大学学报, 2020, 54(12): 1-13.
ZHANG Xining, GUO Qinglin, LIU Shuyu. Analysis and prospect of deep learning technology and its fault diagnosis application [J]. Journal of Xi'an Jiaotong University, 2020, 54(12): 1-13.
- [75] 向宙, 张西宁, 张雯雯, 等. 区分自编码网络及其在滚动轴承故障特征提取中的应用[J]. 西安交通大学学报, 2019, 53(8): 47-55.
XIANG Zhou, ZHANG Xining, ZHANG Wenwen, et al. Discriminative auto-encoding network with applications in fault feature extraction of rolling bearing [J]. Journal of Xi'an Jiaotong University, 2019, 53(8): 47-55.
- [76] GU J, HUANG M, GJORGJEVIKJ D. Fault diagnosis method for bearing of high-speed train based on multitask deep learning [J]. Shock and Vibration, 2020(11): 1-8.
- [77] 王奉涛, 刘晓飞, 敦泊森, 等. 基于萤火虫优化的核自动编码器在中介轴承故障诊断中的应用[J]. 机械工程学报, 2019, 55(7): 58-64.
WANG Fengtao, LIU Xiaofei, DUN Bosen, et al. Application of kernel auto-encoder based on firefly optimization in intershaft bearing fault diagnosis [J]. Journal of Mechanical Engineering, 2019, 55(7): 58-64.
- [78] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报, 2020, 42(1): 234-248.
WEN Chenglin, LÜ Feiya. Review on deep learning based fault diagnosis [J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248.
- [79] CHE C C, WANG H W, NI X M, et al. Hybrid multimodal fusion with deep learning for rolling bearing fault diagnosis [J]. Measurement, 2020, 173: 1-10.
- [80] 石怀涛, 尚亚俊, 白晓天, 等. 基于贝叶斯优化的SWDAE-LSTM滚动轴承早期故障预测方法研究[J]. 振动与冲击, 2021, 40(18): 286-297.
SHI Huaitao, SHANG Yajun, BAI Xiaotian, et al. Early fault prediction method combining SWDAE-LSTM for rolling bearings based on Bayesian optimization [J]. Journal of Vibration and Shock, 2021, 40(18): 286-297.
- [81] 施文锐. 基于深度学习的滚动轴承早期故障诊断研究[D]. 石家庄: 石家庄铁道大学, 2021: 50-63.
SHI Wenrui. Research on early fault diagnosis of rolling bearings based on deep learning [D]. Shijiazhuang: Shijiazhuang Tiedao University, 2021: 50-63.
- [82] 张继旺, 丁克勤, 王洪柱. 基于VMD-CNN的滚动轴承早期微弱故障智能诊断方法[J]. 组合机床与自动化加工技术, 2020, (11): 15-19.
ZHANG Jiawang, DING Keqin, WANG Hongzhu. Rolling bearing early weak fault intelligent diagnosis based on VMD-CNN [J]. Modular Machine Tool & Automatic, 2020(11): 15-19.
- [83] SHAO S, MCALEER S, YAN R, et al. Highly accurate machine fault diagnosis using deep transfer learning [J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455.
- [84] 刘飞, 陈仁文, 邢凯玲, 等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法[J]. 振动与冲击, 2022, 41(3): 154-164.
LIU Fei, CHEN Renwen, XING Kailing, et al. Fast fault diagnosis algorithm for rolling based on transfer learning and deep residual network [J]. Journal of Vibration and Shock, 2022, 41(3): 154-164.
- [85] 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, 41(8): 95-103.
CHEN Renxiang, ZHU Yuqing, HU Xiaolin, et al. Fault diagnosis of rolling bearing under different working conditions using adaptation regularization based transfer learning [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 95-103.
- [86] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究[J]. 西安交通大学学报, 2021, 55(10): 30-37.
ZHANG Xining, YU Di, LIU Shuyu. Fault diagnosis method for small sample bearing based on transfer learning [J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 30-37.
- [87] 沈长青, 王旭, 王冬, 等. 基于多尺度卷积类内迁移学习的列车轴承故障诊断[J]. 交通运输工程学报, 2020, 20(5): 151-164.
SHEN Changqing, WANG Xu, WANG Dong, et al. Multi-scale convolution intra-class transfer learning for train bearing fault diagnosis [J]. Journal of Traffic and Transportation Engineering, 2020, 20(5): 151-164.
- [88] 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 Shouqiang, HU Mingwu, WANG Yujing, 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.
- [89] 陈超, 沈飞, 严如强. 改进LSSVM迁移学习方法的轴承故障诊断[J]. 仪器仪表学报, 2017, 38(1): 33-40.
CHEN Chao, SHEN Fei, YAN Ruqiang. Enhanced least squares support vector machine-based transfer learning strategy for bearing fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 33-40.
- [90] SHEN F, CHEN C, YAN R, et al. Bearing fault diagnosis based on SVD feature extraction and transfer learning classification [C]//2015 Prognostics & System Health Management Conference. Beijing: IEEE, 2016: 1-6.
- [91] 毛文涛, 田思雨, 窦智, 等. 一种基于深度迁移学习的滚动轴承早期故障在线检测方法[J]. 自动化学报, 2022, 48(1): 302-314.
MAO Wentao, TIAN Siyu, DOU Zhi, et al. A new deep transfer learning-based online detection method of rolling bearing early fault [J]. Acta Automatica Sinica, 2022, 48(1): 302-314.

收稿日期: 2022-03-04 修回日期: 2022-05-06

基金项目: 企业信息化与物联网测控技术四川省高校重点实验室(2022WZJ01)

自贡市重点科技计划项目(2019YYJC15)

四川轻化工大学科研基金项目(2020RC32)

四川轻化工大学研究生课程建设项目(KA202003, AL202213)

作者简介: 李兆飞(1982—), 男, 四川雅安人, 博士, 副教授, 硕士生导师; 研究方向为设备状态监测及故障诊断, 人机交互及智能信息处理; lizhaofei825@163.com。