

# 滚动轴承智能故障诊断技术的研究综述与未来展望

钟宇轩 李金花 王艳飞\*

(广州理工学院, 广东 广州 510000)

**摘要:** 滚动轴承智能故障诊断是实现工业装备预测性维护的核心。传统方法依赖人工特征工程, 在复杂工况下泛化能力弱。深度学习通过端到端学习, 可自动从原始数据中提取故障特征, 推动诊断范式变革。当前主流方法包括直接处理一维振动信号的深度时序模型(如1D-CNN)和基于时频图像的视觉模型(如Vision Transformer)。针对数据稀疏、工况变化等挑战, 迁移学习、生成对抗网络等技术被广泛应用。然而, 模型可解释性差、强噪声下鲁棒性不足、小样本泛化能力弱及寿命预测困难仍是工程落地的主要瓶颈。未来研究需聚焦可解释人工智能、数字孪生数据增强、物理信息融合与轻量化边缘部署, 构建更可信、自适应、前瞻的智能诊断系统。

**关键词:** 滚动轴承; 故障诊断; 深度学习; 卷积神经网络; 迁移学习; 可解释人工智能; 预测性维护

**DOI:** <https://doi.org/10.65196/4j5mm340>

## 一、引言

滚动轴承是风力发电、航空发动机、高速列车等高端装备中的关键旋转部件, 其失效常引发连锁故障甚至灾难性事故。工业统计显示, 约30%的旋转机械故障源于轴承损伤。因此, 实现对其状态的精准、实时监测与早期诊断, 对保障设备安全、推行预测性维护至关重要。传统诊断方法依赖专家经验, 通过信号处理(如FFT、小波变换)人工提取特征, 再输入SVM等浅层分类器。该范式虽在特定场景有效, 但存在三大固有缺陷: 特征工程主观性强、工况变化时泛化能力差、难以识别微弱或复合故障。近年来, 深度学习凭借端到端(end-to-end)的自动特征学习能力, 绕过人工设计环节, 显著提升了诊断的自动化与智能化水平。本文系统综述基于深度学习的智能诊断方法, 剖析其技术路径、现实挑战, 并对未来方向进行展望。

## 二、传统故障诊断方法回顾

传统故障诊断方法构成了该领域的理论基础和实践起点, 其典型工作流程可概括为“数据采集 → 信号处理与特征提取 → 状态识别与决策”三个紧密衔接的环节。

在信号处理层面, 振动信号因其对轴承内部缺陷极为敏感而成为最主流的信息载体。时域分析方法通过计算信号的统计特性(如均方根值、峭度)来反映其能量和冲击程度。频域分析则基于傅里叶变换, 通过在频谱中识别轴承的故障特征频率进行诊断。然而, 对于变转速等非平稳信号, 单纯的频域分析会失效。为此, 时频域分析技术(如短时傅里叶变换、小波变换<sup>[1]</sup>、经验模态分解<sup>[2]</sup>及其改进算法)应运而生, 能同时在时频域刻画故障特征<sup>[3, 4]</sup>。研究者们发展了诸如经验快速谱峭度<sup>[5]</sup>、结合变分模态分解与多分类相关向量机<sup>[6]</sup>等多种特征提取与识别方法。这些特征频率的计算公式与轴承的几何参数密切相关。以最常见的外圈故障为例, 其理论特征频率 $f_o$ 可表示为:

$$f_o = \frac{B}{2} \left( 1 - \frac{d}{D} \cos \alpha \right) f_r$$

**作者简介:** 钟宇轩(2005-), 男, 本科, 研究方向为人工智能、自动化。

李金花(2003-), 女, 本科, 研究方向为人工智能、自动化。

**通讯作者:** 王艳飞(1997-), 助教, 研究生。

其中  $B$  为滚动体数量,  $d$  为滚动体直径,  $D$  为轴承节圆直径,  $\alpha$  为接触角,  $f_r$  为轴的旋转频率。然而, 当设备运行在变转速或变负载等非平稳工况下时, 单纯的频域分析会因频率模糊而失效。为此, 时频域分析技术应运而生, 如连续小波变换 (CWT) 能够在时间和频率两个维度上同时刻画信号的能量分布:

$$\text{CWT}(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi^* \left( \frac{t-b}{a} \right) dt$$

其中  $a$  为尺度参数 (反比于频率),  $b$  为时间平移参数,  $\psi(t)$  为母小波函数。CWT 生成的时频图能有效揭示故障冲击发生的具体时刻和对应的频带范围。

在模式识别层面, 从早期的专家系统发展到浅层机器学习模型, 如支持向量机<sup>[7, 6]</sup>和人工神经网络。尽管传统方法积累了丰富的经验, 但其根本缺陷在于特征提取与分类决策的割裂, 性能上深受限于人工特征的质量, 在面对新设备或变工况时缺乏自适应能力<sup>[8]</sup>。

### 三、基于深度学习的智能诊断方法

深度学习的引入, 实现了将特征提取与分类器设计统一在一个端到端的优化框架内, 极大地推动了故障诊断的自动化与智能化进程。根据输入数据的形态和所采用的网络架构, 现有研究主要可分为以下三类。

#### 3.1 一维原始信号模型

这类方法最为直接, 旨在最大限度地保留原始信号中的全部信息。一维卷积神经网络 (1D-CNN) 是处理此类任务的天然选择。设输入振动序列为  $x \in \mathbb{R}^L$ , 长度为  $L$ , 一个尺寸为  $k$  的卷积核  $w \in \mathbb{R}^k$  与其进行卷积运算, 得到第  $i$  个输出特征:

$$(x * w)_i = \sum_{j=1}^k w_j \cdot x_{i+j-1}$$

通过堆叠多个卷积层、池化层和非线性激活函数 (如 ReLU), 网络可以逐层构建从简单冲击脉冲到复杂复合故障模式的层次化特征表示。浅层卷积核通常捕获高频瞬态冲击, 而深层网络则组合这些局部模式形成更具语义的全局表征。为了进一步提升性能, 研究者们常引入残差连接 (ResNet) 以缓解梯度消失问题, 并采用批量归一化 (Batch Normalization) 加速训练收敛。考虑到振动信号本质上是时间序列, 为了捕捉更长距离的时序依赖关系, 将 CNN 与循环神经网络 (RNN) 结合的混合架构 (如 CNN-LSTM) 成为主流。在此基础上, 注意力机制被广泛集成, 使模型能够动态地为不同时间步的特征分配权重。具体而言, 给定 LSTM 输出的隐藏状态序列  $H = [h_1, \dots, h_T]$ , 注意力权重  $\alpha_t$  和上下文向量  $c$  计算如下:

$$\alpha_t = \frac{\exp(\text{score}(h_t))}{\sum_{j=1}^T \exp(\text{score}(h_j))}, \quad c = \sum_{t=1}^T \alpha_t h_t$$

近期, 受自然语言处理领域成功的启发, 一维 Transformer 模型也开始被应用于振动信号分析, 其自注意力机制能够并行地建模序列中任意两点间的长程依赖关系, 在处理长序列数据时展现出优于 RNN 的效率与性能, 但其计算复杂度为  $O(L^2)$ , 对长信号处理构成挑战。

#### 3.2 二维时频/编码图像模型

这类方法巧妙地借鉴了计算机视觉领域的成熟技术和强大模型。首先, 通过时频分析工具 (如

CWT、STFT) 或专门的信号编码技术 (如格拉姆角场 GAF、马尔可夫变迁场 MTF), 将一维振动信号转换为二维图像。以格拉姆角场 (GAF) 为例, 它通过极坐标映射将时间序列  $\mathbf{x}_t$  转换为唯一图像  $G$ , 其元素定义为:

$$G_{ij} = \cos(\phi_i + \phi_j), \quad \text{其中} \quad \phi_t = \arccos\left(\frac{x_t - \min(x)}{\max(x) - \min(x)} \times 2 - 1\right)$$

该变换不仅保留了原始序列的幅值信息, 还严格编码了任意两点间的时序相关性。生成的图像直观地展现了故障特征在时频域的分布规律或序列内部的动态相关性。随后, 可以利用在大规模图像数据集上预训练的、性能卓越的 2D-CNN 架构 (如 ResNet、VGG) 进行特征学习和分类。这种方法的优势在于能够充分利用图像中丰富的空间结构信息, 并且受益于计算机视觉领域数十年的技术积累。近年来, 视觉 Transformer (ViT) 及其变体 (如 Swin Transformer) 开始受到关注。它们通过将图像分割成块并应用自注意力机制, 能够捕捉图像块之间的全局上下文关系, 在处理复杂的时频图像时表现出色。

### 3.3 面向工程挑战的先进策略

针对数据稀缺和工况多变问题, 先进学习策略被广泛探索。生成对抗网络<sup>[9]</sup>可用于数据增强。迁移学习与域自适应技术旨在提升模型在新工况下的泛化能力<sup>[10]</sup>。主要方法对比如表 1 所示。

表 1 滚动轴承智能诊断主流深度学习方法的对比

方法类别	典型技术	输入形态	核心优势	主要局限
一维信号模型	1D-CNN, CNN-LSTM, 1D-Transformer	原始振动序列	端到端、信息无损、计算效率较高	对噪声敏感; Transformer 计算量大
二维图像模型	ResNet + CWT, ViT + GAF	时频图或编码图	可复用成熟 CV 模型; 抗噪性较强	依赖变换质量; 可能引入信息冗余
小样本/跨域学习	GAN, 原型网络, 域自适应	多源、少标签数据	缓解数据稀缺; 提升跨工况泛化能力	GAN 训练不稳定; 域差异大时效果下降

针对小样本与数据不平衡问题, 生成对抗网络 (GAN) 被用来合成逼真的故障振动信号, 以扩充训练集并平衡类别分布。例如, Wasserstein GAN with Gradient Penalty (WGAN-GP) 能生成更稳定的样本。度量学习方法 (如原型网络) 则另辟蹊径, 旨在学习一个度量空间, 使得同类故障样本在该空间中距离相近, 而异类样本距离相远, 从而在仅有少量标记样本的情况下也能实现有效分类。针对跨工况泛化问题, 域自适应 (Domain Adaptation) 技术通过在训练过程中显式地最小化源域 (已知工况) 和目标域 (未知工况) 之间的特征分布差异来学习域不变特征。其中, 最大均值差异 (MMD) 一种常用度量:

$$\text{MMD}^2 = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(x_i^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(x_j^t) \right\|_{\mathcal{H}}^2$$

迁移学习 (Transfer Learning) 则更为直接, 它利用在 ImageNet 等超大规模数据集上预训练好的视觉模型作为起点, 在目标轴承诊断任务上进行微调, 从而实现知识的迁移和快速建模。

## 四、当前面临的核心挑战

尽管基于深度学习的智能诊断方法在公开数据集上取得了卓越的性能, 但其在真实工业场景中的可靠部署仍面临一系列严峻挑战, 这些挑战构成了从学术研究到工程应用的“最后一公里”障碍。

#### 4.1 “黑箱”困境与可解释性缺失

深度神经网络决策过程的不透明性，使其被视为“黑箱”。这不仅导致工程师难以理解和信任模型的诊断结果，更阻碍了模型的优化迭代与故障根因的深度分析。在航空航天、能源核电等安全攸关领域，缺乏解释性的诊断结论难以被接受，构成了技术落地的根本性信任障碍。

#### 4.2 复杂工业环境下的鲁棒性不足

当前研究大多基于 CWRU 等实验室标准数据集，其工况单一、噪声可控。然而，真实工业现场环境极端复杂：存在强烈的、非高斯的背景噪声与电磁干扰；故障信号常与其它部件的振动耦合；负载与转速呈连续、随机波动。现有模型在此类高度非平稳、强干扰环境下的泛化能力与稳定性，尚未得到充分验证。

#### 4.3 数据瓶颈与模型泛化能力受限

深度学习的性能严重依赖大量高质量标注数据。但工业现场获取早期、罕见故障的样本成本极高、周期长，形成严重的数据瓶颈。更严峻的是，在某一设备或工况下训练的模型，往往难以直接泛化到另一台型号相似但工况、磨损状态不同的设备上，即面临严峻的“域泛化”和“少样本/零样本学习”挑战。

#### 4.4 从“状态诊断”到“寿命预测”的范式升级困难

当前研究多聚焦于故障类型的分类与识别，属于“事后”或“事中”分析。而工业运维的核心需求是“事前”的剩余使用寿命预测。RUL 预测是一个复杂的时序回归问题，需对设备非线性、个性化的退化轨迹进行精确建模，并量化预测的不确定性。其技术难度远超故障分类，是智能诊断价值跃迁的关键。

### 五、未来研究展望

为有效应对上述挑战，推动智能诊断技术从“实验室可用”走向“工业现场好用、敢用”，未来的研究工作需在以下几个关键方向寻求突破。这些方向不仅针对具体技术瓶颈，更致力于构建可信、可靠、可用的下一代智能诊断生态系统。

#### 5.1 发展可解释人工智能，破解“黑箱”困境

模型的可解释性是建立技术信任的基石。未来研究需大力推动可解释人工智能（XAI）技术与诊断模型的深度融合。

可视化诊断依据：应用如 Grad-CAM、梯度加权类激活映射等技术，将 1D-CNN 或 2D-CNN 的决策依据可视化。例如，为振动信号生成热力图，明确标出模型判定故障的关键冲击时段或频带。

理解复杂模型机制：利用注意力权重分析，阐释 Transformer 等模型内部的特征聚焦机制，理解其如何整合全局与局部信息。

发展高级解释方法：探索反事实解释等进阶方法，能够回答“为何不是其他故障类型”的对比性问题。

核心目标是构建“灰盒化”乃至“白盒化”的诊断模型，使其决策过程对工程师透明，从而实现可信的人机协同诊断与高效的模型迭代优化。

#### 5.2 构建数字孪生增强体系，突破数据与验证瓶颈

数字孪生技术为克服数据稀缺和验证困难提供了革命性路径。高保真仿真与数据生成：利用多体动力学（如 SIMPACK）与有限元分析（如 ANSYS）软件，构建轴承-转子系统的高保真虚拟镜像。通过模拟各类正常、故障及渐进退化过程，生成海量带精确物理标签（故障位置、尺寸、工况）的仿真数据。赋能模型训练与评估，生成的数据可用于：1) 预训练诊断模型，提升其初始特征提取能力；2) 扩充罕见故障样本库，解决数据不平衡问题；3) 构建故障演化知识图谱，支持 RUL 预测模型训练。

打造算法验证“沙盒”：数字孪生体可作为安全、低成本的虚拟测试平台，用于验证和比较不同算法在极端、危险工况下的性能与鲁棒性，极大降低现场试验风险与成本。

### 5.3 融合物理信息与数据驱动，提升模型外推与泛化能力

为减少对大规模标注数据的依赖并提升模型在未知场景下的可靠性，需推动数据驱动与物理模型的深度融合。

物理引导的深度学习：将轴承动力学、摩擦学、疲劳失效等领域的先验知识，以物理约束（如嵌入 Hertz 接触理论的损失函数正则项）或结构化网络（如编码运动微分方程的物理信息神经网络 PINNs）形式，嵌入深度学习框架。

实现可解释泛化：这种“物理引导的数据驱动”范式，能迫使模型学习符合物理规律的本质特征，从而显著增强其在训练数据分布之外的外推能力，并提升模型决策的物理可解释性。

### 5.4 深化自监督与元学习，实现小样本快速自适应

为应对工业现场标注数据稀缺、设备个体差异大的挑战，需充分利用无标签数据并赋予模型快速自适应能力。

自监督预训练：利用海量无标签的正常工况数据，通过设计掩码信号重建、对比学习等自监督任务，预训练一个强大的通用特征提取器。在此基础上，仅需少量故障标签进行微调，即可获得高性能诊断模型。

元学习实现“学会学习”：发展高效的元学习与度量学习算法，使模型具备从少量新设备、新故障样本中快速学习的能力，实现“一次建模，多处适应”，从根本上解决跨设备、跨工况的泛化难题。

### 5.5 推动边缘智能部署，实现实时轻量监测

最终的落地形式需满足工业现场对实时性、可靠性与低功耗的严格要求。

模型压缩与加速：深入研究面向嵌入式设备的网络剪枝、参数量化（如 INT8）、知识蒸馏等模型轻量化技术，在精度损失最小化的前提下，大幅降低模型计算复杂度、存储需求和功耗。

开发自适应边缘算法：开发能够在资源受限的边缘计算节点上运行，并具备在线持续学习能力的轻量级算法，使其能自适应跟踪设备的缓慢退化过程，实现真正的实时、自主、低功耗智能监测。

综上所述，通过在上述五个方向的协同推进，有望系统性地解决当前智能诊断技术面临的核心障碍，最终构建出可信、自适应、经济且具备预测能力的下一代工业智能健康管理系统。

## 六、结论

过去十余年，滚动轴承智能故障诊断技术在深度学习的强力驱动下，实现了从“人工特征设计”到“自动特征学习”的历史性范式跃迁。本文系统地回顾了传统方法的局限，详细分类评述了当前主流的深度学习诊断技术路径，并深入剖析了其在迈向大规模工业应用过程中所面临的核心挑战。站在新的发展起点上，我们必须清醒地认识到，未来的研究重心将不再仅仅是追求更高的诊断准确率，而是要致力于构建一个集可信、自适应、经济、前瞻于一体的智能诊断生态系统。这需要机械工程、数据科学、失效物理、计算机硬件等多个学科的深度交叉与协同创新。通过积极拥抱可解释人工智能、数字孪生、物理信息融合、自监督学习等前沿方向，滚动轴承智能故障诊断技术必将演进为支撑智能制造与工业互联网体系的关键使能技术，为实现装备全生命周期的高效、安全、自主管理奠定坚实的基础。

#### 参考文献：

- [1] Li H X. Bearing fault diagnosis based on wavelet analysis[J]. *Advanced Materials Research*, 2013, 706: 1763-1768.
- [2] 郭奇, 刘卜瑜, 史立波, 等. 基于二次 EEMD 的 Wigner-Ville 分布旋转机械故障信号分析及试验研究[J]. *振动与冲击*, 2012, 31(13): 129-133.
- [3] Smith J S. The local mean decomposition and its application to EEG perception data[J]. *Journal of the Royal Society Interface*, 2005, 2(5): 443-454.
- [4] Li Y, Xu M, Wang R, et al. A fault diagnosis scheme for rolling bearing based on local mean decomposition and improved multiscale fuzzy entropy[J]. *Journal of Sound and Vibration*, 2016, 360: 277-299.
- [5] 张坤, 胥永刚, 马朝永, 等. 经验快速谱峭度及其在滚动轴承故障诊断中的应用[J]. *振动工程学报*, 2020,

33(3): 636-642.

[6] 陈鹏, 赵小强, 朱奇先. 基于 VMD-MPE-KPCA 特征提取与 MRVM 相混合的滚动轴承故障诊断方法[J]. 兰州理工大学学报, 2020, 46(5): 92.

[7] 朱俊杰, 张清华, 朱冠华, 等. 基于 EEMD 和 CNN-SVM 的滚动轴承故障诊断[J]. Machine Tool & Hydraulics, 2024, 52(17).

[8] Zhang Y, Tang B, Han Y, et al. Bearing performance degradation assessment based on time-frequency code features and SOM network[J]. Measurement Science and Technology, 2017, 28(4): 045601.

[9] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. science, 2006, 313(5786): 504-507.

[10] Zhang Q, Yang L T, Chen Z, et al. A survey on deep learning for big data[J]. Information Fusion, 2018, 42: 146-157.

## Research Review and Future Prospects of Intelligent Fault Diagnosis Technology for Rolling Bearings

ZHONG Yunxuan, LI Jinhua, WANG Yanfei\*

*(Guangzhou Institute of Science and Technology, Guangzhou, Guangdong 510000, China)*

**Abstract:** Intelligent fault diagnosis for rolling bearings is central to achieving predictive maintenance in industrial equipment. Traditional methods rely on manual feature engineering and exhibit weak generalization under complex operating conditions. Deep learning, through end-to-end learning, can automatically extract fault features from raw data, driving a paradigm shift in diagnostic approaches. Current mainstream methods include deep temporal models that directly process one-dimensional vibration signals (e.g., 1D-CNN) and visual models based on time-frequency images (e.g., Vision Transformer). To address challenges such as data scarcity and varying working conditions, techniques like transfer learning and generative adversarial networks have been widely applied. However, key bottlenecks for practical engineering implementation remain, including poor model interpretability, insufficient robustness under strong noise, weak generalization with small samples, and difficulties in lifetime prediction. Future research should focus on explainable artificial intelligence, digital twin-based data augmentation, physics-informed data fusion, and lightweight edge deployment to build more trustworthy, adaptive, and forward-looking intelligent diagnostic systems.

**Keywords:** Rolling bearing; Fault diagnosis; Deep learning; Convolutional neural network (CNN); Transfer learning; Explainable artificial intelligence (XAI); Predictive maintenance