

基于深度学习的谐波减速器故障诊断方法综述

韦赤冰

贵州航天群建精密机械有限公司 贵州 贵阳 550000

【摘要】：谐波减速器是工业机器人的核心精密传动部件，其运行状态直接决定机器人的精度与可靠性。由于其结构复杂且长期处于重载、变工况环境，易出现刚轮齿面损伤、柔轮疲劳断裂等故障。传统诊断方法依赖人工特征提取与专家经验，在强噪声、非平稳信号下性能受限。深度学习以其强大的自动特征学习与端到端诊断能力，为该领域提供了新的解决方案。本文系统综述了深度学习在该领域的研究进展：首先阐述了谐波减速器的典型故障机理及其振动信号的非平稳、非线性与强噪声特性；进而，依据模型架构，详细分析了卷积神经网络、循环神经网络、混合模型、迁移学习及多源信息融合等主流方法的原理、创新与性能，并对比了其优缺点；最后，探讨了小样本学习、强噪声与复合故障诊断、模型轻量化与边缘部署等当前挑战，并展望了数字孪生融合、小样本学习、自适应轻量化模型等未来方向，旨在为后续研究与工程应用提供参考。

【关键词】：谐波减速器；故障诊断；深度学习；卷积神经网络；迁移学习

DOI:10.12417/2705-0998.26.01.002

1 引言

1.1 研究背景与意义

谐波减速器作为关键的传动部件，广泛应用于工业机器人与航空航天领域中，其可靠性直接决定整机性能，是精密传动的核心部件^[1]。核心结构由柔轮、刚轮和波发生器组成，实现高减速比与精密运动控制^[2]。其结构复杂，且长期工作在重载、变转速、强噪声的恶劣环境下，故障率较高。传统故障诊断方法依赖信号处理与专家经验提取特征，难以应对变工况与非平稳信号。

深度学习技术凭借强大的特征自动提取与非线性拟合能力，为智能故障诊断开辟了新路径。它能够从原始信号中直接挖掘故障表征，实现端到端诊断，降低了对人工先验知识的依赖。因此，系统梳理深度学习在该领域的研究成果，分析各类方法的优劣，对推动技术发展与应用具有重要意义。

2 谐波减速器故障类型与信号特性

2.1 常见故障类型

谐波减速器的故障类型与结构特性、工作工况密切相关，根据故障成因与表现形式，可分为以下三类：

(1) 材料/结构损伤故障：如齿面擦伤、柔轮疲劳断裂、轴承剥落磨损，由长期交变应力或磨损导致

(2) 装配/形位故障：如波发生器不对中、同轴度误差，由安装缺陷引起，导致载荷不均。

(3) 润滑失效故障：因润滑不良导致摩擦加剧，诱发磨损。

2.2 故障信号特性

谐波减速器的故障特征主要通过振动信号、声发射信号等方式体现，其信号具有以下典型特性：

(1) 非平稳性：谐波减速器运行时，转速、负载的波动，

以及故障发展过程中的特征变化，导致振动信号的统计特性（均值、方差、频率成分）随时间变化，呈现明显的非平稳性。

(2) 非线性：由于柔轮的弹性变形、齿面啮合的非线性接触、部件间的摩擦碰撞等因素，振动信号呈现强烈的非线性特性，表现为谐波失真、频率调制等现象。

(3) 强噪声干扰：工业现场的环境噪声、电机振动、其他传动部件的干扰，导致故障信号被严重掩盖，尤其是早期故障，特征信号微弱，难以直接提取。

(4) 多尺度特性：故障特征分布在不同的时间尺度与频率尺度上。例如，齿面擦伤的特征频率主要集中在中高频段，而波发生器不对中的特征频率则在低频段更为显著。

这些信号特性给故障诊断带来了巨大挑战，而深度学习模型凭借强大的非线性拟合能力、多尺度特征提取能力，能够有效处理此类复杂信号，为提高诊断性能提供了技术支撑。

3 基于深度学习的谐波减速器故障诊断方法研究进展

深度学习模型通过构建多层神经网络，自动学习数据中的深层特征，无需人工设计特征指标，已在谐波减速器故障诊断中形成多种技术路径。根据模型结构与核心思想，可分为基于卷积神经网络(CNN)的方法、基于循环神经网络(RNN/LSTM)的方法、混合深度学习模型、基于迁移学习的方法、多源信息融合与深度学习结合的方法等五大类，以下详细阐述各类方法的研究进展。

3.1 基于卷积神经网络(CNN)的故障诊断方法

卷积神经网络(CNN)通过卷积层、池化层的交替堆叠，能够有效提取数据中的空间特征与局部相关性，尤其适用于处理多维信号与图像类数据。在谐波减速器故障诊断中，CNN常被用于处理振动信号转换后的时频图（如小波变换时频图、短时傅里叶变换时频图），或直接处理一维振动信号，通过一

维卷积提取故障特征。

针对振动信号的多尺度特性与多传感器信息，研究者提出了多种改进 CNN 结构。例如，Yang^[3]等人提出多尺度卷积神经网络，通过构建多尺度粗粒度特征层，利用 2D-CNN 自适应提取不同时间尺度下的故障特征，有效提升了模型对多工况的适应能力。He^[4]等人则面向工业机器人原位诊断场景，设计了多尺度混合卷积神经网络，其通过多分支注意力机制与不同扩张率的扩张卷积，从复杂的多通道现场信号中提取互补的多尺度特征，解决了强噪声干扰问题。陈仁祥等人^[5]构建了多特征空间自适应网络，利用自适应网络将源域中学习到的知识自动应用到目标域，以自动对齐特定领域的特征分布，从而学习多个域不变表示，提升了对早期故障的敏感度。

基于 CNN 的方法优势在于强大的特征提取能力与并行计算效率，能够处理高维、多尺度的故障信号。但单一 CNN 模型难以捕捉振动信号的时序相关性，对于具有明显时序特征的故障（如轴承磨损的渐进性故障），诊断性能有限，通常需要与其他模型结合使用。

3.2 基于循环神经网络（RNN/LSTM）的故障诊断方法

循环神经网络及其变体（如 LSTM、GRU）通过内部循环结构记忆历史信息，特别适用于处理具有时序依赖性的振动信号。它们能够捕捉故障特征的演化规律，对渐进性故障诊断具有优势。为应对强噪声环境，Zhi 等人^[6]提出了结合小波区域相关阈值去噪与 CNN-LSTM 的混合方法。该方法先利用改进的小波阈值算法抑制噪声，再通过 CNN 提取空间特征，最后由 LSTM 学习时序依赖关系，显著提升了噪声下的诊断精度。

基于 LSTM 的方法优势在于能够捕捉时序信号的长期依赖关系，对于渐进性故障、复合故障的诊断具有独特优势。但单一 LSTM 模型的特征提取能力有限，难以挖掘信号中的局部空间特征，通常需要与 CNN 等模型结合，形成混合深度学习模型。

3.3 混合深度学习模型

混合模型旨在集成不同网络的优点，实现特征提取能力的互补。最常见的组合是 CNN 与 LSTM/GRU 的串联或并联，以同时捕获信号的空间局部特征与时间全局依赖。此外，CNN 与注意力机制、残差网络的结合也颇为常见。康守强等人^[7]提出了一种信息融合子域适应方法，其核心是改进的残差网络。该方法首先融合多传感器时频图，再利用改进的残差网络挖掘多表示特征，并通过子域适应技术减小不同工况下特征分布的差异，实现了无监督跨工况诊断。

混合深度学习模型的优势在于能够互补不同模型的性能短板，同时处理信号的空间特征、时序特征与多尺度特征，适用于复杂工业场景下的故障诊断。但这类模型的结构通常较为复杂，训练成本较高，需要大量标注数据支撑。

3.4 基于迁移学习的故障诊断方法

工业现场常面临变工况、样本稀缺等问题，导致模型泛化能力下降。迁移学习通过迁移源域（标注充足）的知识至目标域（标注稀缺或无标注），可有效缓解数据分布差异带来的挑战。石超等人^[8]提出了一种基于改进联合分布适配和支持向量机的迁移模型(方法),从而对谐波减速器进行了故障诊断。

基于迁移学习的方法能够有效解决变工况、标签缺失、数据不平衡等工业现场常见问题，增强了模型的实用性。但当前方法多聚焦于单一迁移场景（如跨转速、跨负载），对于多因素耦合的复杂工况迁移（如同时跨转速、跨负载、跨个体），仍需进一步研究。

3.5 多源信息融合与深度学习结合的方法

单一传感器获取的信号往往难以全面反映谐波减速器的运行状态，易受安装位置、环境干扰的影响，导致诊断结果不可靠。多源信息融合通过整合多个传感器（如振动传感器、声发射传感器、温度传感器）的信号，能够提供更全面、冗余的故障信息，提升诊断的准确性与鲁棒性。王玉静等人^[9]将数字孪生与深度学习相结合。该方法首先构建故障数字孪生模型生成仿真数据，通过循环生成对抗网络实现仿真与实测数据的虚实映射以扩充数据，再利用深度残差收缩网络提取特征并进行域适应处理，最终在少量实测数据下实现了高精度的跨工况诊断。但这类方法面临传感器部署成本高、多源数据同步难、数据维度高等问题，需要进一步优化传感器选型与数据融合策略。

4 当前研究面临的挑战

尽管基于深度学习的谐波减速器故障诊断方法已取得显著进展，但在工业现场应用中仍面临诸多挑战：

（1）小样本学习问题：故障样本，尤其是早期和严重故障样本稀缺且标注困难，数据驱动深度模型容易过拟合，泛化能力不足。

（2）强噪声与复合故障诊断：现场强噪声严重干扰微弱故障特征的提取；同时，并发复合故障的特征相互耦合、叠加，难以解耦与辨识。

（3）模型实时性与轻量化需求：现有先进模型复杂度高，推理速度难以满足在线实时监测需求；同时，工业边缘设备计算资源有限，亟需轻量级模型部署方案。

（4）复杂多变工况的适应：实际工况是转速、负载、温度等多因素动态耦合，现有迁移学习方法对如此复杂的域间分布差异适应能力有限。

5 未来发展趋势展望

针对当前研究面临的挑战，结合深度学习与工业诊断技术的发展趋势，未来基于深度学习的谐波减速器故障诊断方法可

从以下方向展开研究:

(1) 发展小样本与自监督学习范式: 探索元学习、度量学习、生成对抗网络数据增强以及自监督预训练等技术, 降低模型对大量标注数据的依赖。

(2) 增强模型的抗噪与解耦能力: 研究结合自适应信号降噪的深度学习模型, 以及引入注意力机制、解耦表征学习等技术, 提升模型在强噪声下识别和分离复合故障特征的能力。

(3) 推动模型轻量化与边缘智能部署: 利用网络剪枝、量化、知识蒸馏等技术压缩模型; 设计适用于嵌入式设备的轻量级网络架构(如 MobileNet、SqueezeNet 变种); 结合边缘计算框架, 实现诊断算法的前端部署。

(4) 深化数字孪生与物理信息融合: 构建高保真数字孪生模型, 生成海量、多故障、多工况的仿真数据以辅助训练; 探索将物理模型(如动力学方程)的先验知识嵌入深度学习框架, 提升模型的可解释性与泛化性。

(5) 探索更鲁棒的跨域迁移学习方法: 研究针对多因素耦合复杂工况的域泛化、元迁移学习等方法, 以及基于联邦学习的分布式协同诊断架构, 在保护数据隐私的同时利用多方数据提升模型性能。

6 结论

本文系统综述了基于深度学习的谐波减速器故障诊断方法。通过分析谐波减速器的故障特性与信号难点, 梳理并对比了 CNN、RNN、混合模型、迁移学习及多源融合等主流技术路线的原理、创新与性能。分析表明, 混合深度学习模型通过优势互补, 通常能取得最佳综合性能; 迁移学习与多源信息融合是提升模型工程实用性的关键。当前, 该领域的研究正朝着解决小样本、高噪声、复合故障、实时轻量化等实际挑战的方向深入。未来, 随着小样本学习、模型压缩、数字孪生等技术的进一步发展, 深度学习驱动的谐波减速器故障诊断有望实现更高精度、更强鲁棒性与更优工程适用性, 为智能制造系统的预测性维护提供坚实支撑。

参考文献:

- [1] 邵未龙,李鹭扬,叶雯莉,等.基于神经网络的小型谐波柔轮结构参数优化[J].机械传动,2025,49(09):47-54.
- [2] 梅杰,张彤,郭政,等.杯形谐波减速器齿廓修形方法及寿命预测分析[J].机械传动,2024,48(10):51-60.
- [3] YANG G,ZHONG Y,YANG L,et al.Fault Detection of Harmonic Drive Using Multiscale Convolutional Neural Network[J].IEEE Transactions on Instrumentation and Measurement,2021,70.
- [4] HE Y M,CHEN J H,ZHOU X,et al.In-situ fault diagnosis for the harmonic reducer of industrial robots via multi-scale mixed convolutional neural networks[J].Journal of Manufacturing Systems,2023,66233-247.
- [5] 陈仁祥,张晓,李嘉琳,等.基于多特征空间自适应网络的谐波减速器故障诊断[J].振动工程学报,2025,38(02):432-440.
- [6] Zhi Z,Liu L,Liu D,et al.Fault detection of the harmonic reducer based on CNN-LSTM with a novel denoising algorithm[J].IEEE Sensors Journal,2021,22(3):2572-2581.
- [7] 康守强,章炜东,王玉静,等.基于信息融合子域适应的不同工况下谐波减速器故障诊断方法[J].仪器仪表学报,2024,45(3):61-71.
- [8] 石超,刘彪,郭世杰,等.基于改进联合分布适配和支持向量机的谐波减速器故障诊断[J].机电工程,2025,42(03):441-450.
- [9] 王玉静,李祎然,康守强,等.基于数字孪生的不同工况下谐波减速器故障诊断方法[J].机械工程学报,2025,61(18):12-26.