

基于深度学习的旋转机械故障特征提取与诊断

李 辉

河南钢铁集团安阳钢铁股份有限公司 运输作业部 河南 安阳 455000

摘 要: 况下的非线性信号。深度学习通过端到端学习机制,可自动提取振动信号中的故障特征,突破人工特征工程的局限性。本文围绕旋转机械故障特征提取与诊断,系统阐述故障类型与信号特性,分析卷积神经网络、循环神经网络等深度学习模型的适配性,提出基于深度学习的特征提取流程与诊断框架,并探讨轻量化设计、多模态融合等优化方向,为工业场景下的智能故障诊断提供理论支撑与实践参考。

关键词: 旋转机械;深度学习;故障特征提取;故障诊断;模型优化

引言: 旋转机械是工业生产的核心设备,其运行状态关乎生产效率与安全,故障不仅会造成设备损坏,还可能引发安全事故,带来巨大经济损失。传统故障诊断依赖人工特征提取,存在主观性强、适应性差、难以应对复杂非线性信号等问题。深度学习凭借强大的特征自动提取与非线性建模能力,通过端到端学习机制,可直接从原始振动信号中挖掘故障特征,突破人工特征工程局限,为旋转机械故障诊断带来新契机。研究基于深度学习的相关方法,对提升诊断准确性与效率、保障工业生产稳定运行意义重大。

1 旋转机械故障相关基础

1.1 旋转机械常见故障类型

旋转机械作为工业生产中的核心设备,其运行状态直接影响生产效率与安全性。常见故障类型涵盖机械结构与运行环境两大维度^[1]。从机械结构层面分析,转子不平衡是典型故障,因制造误差或长期运行导致质量分布不均,引发周期性振动;转子不对中则源于安装偏差或热变形,造成轴系连接处径向或轴向位移,加剧机械磨损;轴承故障包括内圈、外圈及滚动体损伤,多因润滑不足或过载运行导致接触疲劳;齿轮故障表现为齿面磨损、点蚀或断齿,与传动系统设计参数及载荷波动密切相关。从运行环境角度,油膜振荡是滑动轴承特有的故障模式,与润滑油黏度、轴颈转速及负载共同作用;流体诱导振动常见于叶轮机械,因流体介质压力脉动或气蚀效应引发结构共振;此外,机械松动故障源于部件连接刚度不足,在交变载荷作用下产生非线性振动特征。

1.2 旋转机械故障信号特性

旋转机械故障信号呈现多维时空特性。时域信号中,冲击性故障如齿轮断齿会产生周期性瞬态冲击,其幅值与频率成分随故障程度加剧而显著增强;渐变性故障如轴承磨损则表现为振动能量缓慢累积,有效值与峰值指

标呈非线性增长趋势。频域信号方面,转子不平衡故障在基频处形成明显峰值,不对中故障除基频外还伴随二倍频分量,油膜振荡则表现为低频涡动频率与转子临界转速的耦合特征。时频域分析揭示,非平稳故障信号如流体诱导振动具有瞬态能量集中特性,小波变换可有效捕捉其时间-频率联合分布特征。此外,多源故障耦合作用下,信号呈现非线性调制现象,需通过包络解调或高阶谱分析提取故障特征频率。

1.3 故障特征提取核心需求

旋转机械故障特征提取需满足三大核心需求。其一,信号解耦能力要求从复杂振动信号中分离故障源特征,避免多故障耦合导致的特征湮没,需结合盲源分离或独立分量分析技术实现信号解混。其二,特征敏感性要求所提取指标对早期故障具有高响应度,如峭度指标对冲击性故障的检测灵敏度优于传统时域参数,谱峭度方法可有效定位瞬态故障成分。其三,鲁棒性要求特征提取算法对工况波动具有适应性,基于深度学习的迁移学习框架可实现不同负载条件下的故障模式识别,而自适应滤波技术可抑制环境噪声对特征提取的干扰。此外,实时性需求推动特征提取算法向轻量化发展,基于边缘计算的嵌入式系统可实现故障特征的在线监测与预警。

2 深度学习相关基础理论

2.1 深度学习核心原理

深度学习以人工神经网络为基本框架,通过构建多层非线性变换结构实现数据特征自动提取与模式识别^[2]。其核心在于利用反向传播算法优化网络参数,使模型输出逐步逼近真实标签。这一过程依赖链式法则计算梯度,结合随机梯度下降等优化策略实现参数迭代更新。深度神经网络的层次化结构赋予模型强大的表征学习能力,底层网络捕捉数据局部特征,高层网络通过非线性组合形成全局抽象表示。这种自底向上的特征学习机制突破

了传统机器学习对人工特征工程的依赖，尤其在处理高维非结构化数据时展现出显著优势。网络深度的增加虽提升了模型容量，但也带来梯度消失或爆炸问题，为此发展出残差连接、批量归一化等改进技术，确保深层网络训练稳定性。此外，注意力机制的引入使模型能够动态聚焦关键特征区域，进一步提升了特征提取的精准度。

2.2 适用于故障诊断的深度学习模型类别

针对旋转机械故障诊断任务，卷积神经网络凭借局部感知与权值共享特性，成为处理振动信号时频图像的主流模型。其卷积核通过滑动窗口提取空间局部特征，池化层实现特征降维与平移不变性，特别适用于轴承、齿轮等部件的故障模式识别。循环神经网络及其变体通过引入时序依赖关系，有效建模振动信号的动态演化过程，长短期记忆网络与门控循环单元通过记忆单元与门控机制解决了传统RNN的长期依赖问题，在变工况条件下的故障预测中表现突出。自编码器通过无监督学习重构输入数据，其编码器部分可提取故障特征的低维表示，去噪自编码器通过引入噪声鲁棒性训练，进一步提升了特征提取的抗干扰能力。生成对抗网络通过判别器与生成器的对抗训练，能够生成与真实故障数据分布相近的合成样本，有效缓解故障数据不平衡问题，为模型训练提供更丰富的特征空间。

2.3 深度学习在故障特征提取中的适配性

深度学习模型通过端到端学习机制，直接建立原始振动信号与故障类型的映射关系，避免了传统方法中人工特征设计的主观性与局限性。卷积神经网络的层次化特征提取能力，可自动识别信号中的冲击成分、调制特征等故障指示信息，其局部连接结构与振动信号的短时平稳特性高度契合。循环神经网络对时序数据的建模优势，使其能够捕捉故障发展过程中的动态特征变化，尤其适用于早期故障的微弱信号检测。深度学习模型的非线性映射能力可有效处理故障信号中的噪声干扰与多源耦合问题，通过数据驱动方式学习故障特征与健康状态的复杂非线性关系。此外，迁移学习技术通过预训练模型的知识迁移，解决了小样本条件下故障诊断模型的泛化问题，使深度学习在工业场景中的落地应用成为可能。模型解释性研究的发展，如梯度加权类激活映射等方法，进一步提升了深度学习在故障诊断中的可信度，为工程应用提供了理论支撑。

3 基于深度学习的旋转机械故障特征提取方法

3.1 故障信号预处理方法

旋转机械振动信号的预处理是深度学习模型有效提取特征的基础环节。针对原始信号中混杂的噪声干扰，

小波阈值去噪通过分解信号至不同频带，对高频噪声成分进行软阈值或硬阈值处理，在保留故障特征的同时抑制背景噪声^[3]。经验模态分解则将非平稳信号自适应分解为若干本征模态函数，通过筛选包含主要故障信息的分量重构信号，有效解决传统滤波方法对信号频带假设的依赖问题。对于多传感器采集的信号，数据融合技术通过加权平均或主成分分析实现多通道信息互补，增强故障特征的显著性。此外，归一化处理将信号幅值映射至固定区间，消除量纲差异对模型训练的影响，加速神经网络参数收敛速度。针对时序信号的动态特性，滑动窗口分割将连续信号转化为离散样本序列，窗口长度与步长的选择需兼顾故障特征的时间局部性与模型计算效率。

3.2 基于深度学习的特征自动提取流程

深度学习框架下的特征提取流程以数据驱动为核心，通过构建端到端模型实现从原始信号到故障特征的自动映射。输入层接收预处理后的振动信号或时频图像，卷积层利用局部感受野与权值共享机制提取信号的空间局部特征，池化层通过降采样增强特征平移不变性并减少参数规模。针对时序信号，循环神经网络层通过门控机制建模特征的时间依赖关系，捕捉故障发展的动态演化规律。特征融合层将不同层次、不同模态的特征进行拼接或加权组合，形成包含多尺度信息的综合特征表示。全连接层对融合特征进行非线性变换，输出故障类别概率分布。训练阶段采用交叉熵损失函数衡量预测结果与真实标签的差异，结合反向传播算法与自适应优化器迭代更新网络参数，使模型逐步具备区分不同故障模式的能力。推理阶段通过前向传播获取输入信号的故障特征表示，为后续诊断决策提供依据。

3.3 不同深度学习模型的特征提取机制

卷积神经网络通过卷积核的滑动操作实现特征的空间局部感知，浅层卷积核捕捉信号边缘、纹理等低级特征，深层卷积核通过非线性组合形成包含故障类型信息的高级特征。残差连接通过引入跳跃路径缓解深层网络梯度消失问题，使模型能够学习更复杂的特征变换。循环神经网络利用隐藏状态传递时序信息，长短期记忆网络通过输入门、遗忘门与输出门控制信息流动，有效建模故障特征的长期依赖关系。门控循环单元简化门控结构，在保持模型性能的同时降低计算复杂度。自编码器通过编码器将输入信号压缩为低维潜在表示，解码器重构信号并计算重构误差，潜在表示即作为故障特征用于分类任务。变分自编码器引入概率分布假设，增强特征空间的连续性与可解释性。生成对抗网络中生成器与判别器的对抗训练使模型学习真实故障数据的分布特征，

判别器中间层提取的特征包含丰富的故障判别信息,可用于迁移学习与小样本诊断任务。

4 基于深度学习的旋转机械故障诊断流程

4.1 故障诊断整体框架

旋转机械故障诊断的深度学习框架以数据驱动为核心,构建从信号采集到决策输出的完整闭环。输入层接收多传感器采集的振动、温度、转速等多元信号,经预处理模块完成去噪、归一化及特征增强后,转化为适合模型处理的标准化数据^[4]。特征提取层采用卷积神经网络或循环神经网络等结构,自动学习信号中的故障指示特征,形成高维特征表示。分类决策层通过全连接网络或注意力机制对特征进行非线性映射,输出故障类型概率分布。反馈优化机制将诊断结果与真实标签对比,计算损失函数并反向传播调整模型参数,形成持续迭代的诊断能力。模型部署阶段将训练好的网络封装为轻量化推理引擎,嵌入边缘计算设备实现实时在线诊断,同时通过云端数据回传支持模型持续学习与性能升级。

4.2 基于深度学习的故障识别机制

深度学习模型的故障识别能力源于对复杂非线性关系的建模能力。卷积神经网络通过局部感受野与权值共享机制,自动提取信号中的冲击成分、调制特征等故障指示信息,其层次化结构使模型能够从低级边缘特征逐步抽象为高级故障模式。循环神经网络利用隐藏状态传递时序信息,通过门控机制建模故障发展的动态演化过程,尤其适用于变工况条件下的早期故障检测。注意力机制通过为不同特征分配权重,使模型聚焦关键故障区域,提升微弱故障信号的识别精度。迁移学习技术将预训练模型的知识迁移至目标任务,解决小样本条件下模型泛化问题,通过微调少量参数即可适应不同设备或工况的诊断需求。模型解释性方法如梯度加权类激活映射,通过可视化特征重要性分布,增强诊断结果的可信度与工程适用性。

4.3 故障诊断的流程优化方向

诊断流程优化聚焦于提升模型效率、适应性与可解释性。轻量化设计通过模型剪枝、量化及知识蒸馏等技术,减少参数量与计算复杂度,使模型能够部署于资源

受限的边缘设备,实现毫秒级实时诊断^[5]。自适应学习机制引入在线更新模块,使模型能够根据新采集数据动态调整参数,应对设备老化或工况变化带来的数据分布偏移问题。多模态融合技术整合振动、声发射、电流等多源信号,通过跨模态特征交互增强故障表征的全面性,解决单一传感器信息不足导致的误诊问题。可解释性增强方向发展基于物理约束的混合模型,将机械动力学方程嵌入神经网络结构,使模型输出符合物理规律,同时通过特征归因分析揭示故障根源,为维修决策提供理论依据。

结束语

基于深度学习的旋转机械故障特征提取与诊断方法,通过构建端到端模型,实现了从原始信号到故障类型的自动映射,有效解决了传统方法在特征提取与诊断中的局限性。在故障信号预处理、特征自动提取及诊断流程优化等方面取得一定成果,提升了故障诊断的准确性、实时性与适应性。然而,深度学习模型的可解释性、复杂工况下的适应性问题仍需进一步研究。后续可结合更多物理知识与工程经验,推动深度学习在旋转机械故障诊断领域的深入应用与发展。

参考文献

- [1]官文峰,张美玲,陈辉.基于深度学习的旋转机械大数据智能故障诊断方法[J].计算机集成制造系统,2025,31(1): 264-277.
- [2]黄晨,谈莉斌.改进深度学习模型的旋转机械智能故障诊断方法[J].安徽工业大学学报(自然科学版),2026,43(1): 43-51.
- [3]李文赞,刘勤明,叶春明,等.基于深度学习与SMOTE数据增强的旋转机械故障诊断研究[J].机械强度,2026,48(2): 1-11.
- [4]陶明珠.基于BSS-HHT优化数学模型的旋转机械故障特征提取与诊断[J].机械设计与制造工程,2023,52(11): 67-72.
- [5]郭海宇,邹圣公,张晓光,等.基于多源小波变换神经网络的旋转机械轴承故障诊断[J].中国机械工程,2024,35(11):2026-2034.