

工业机器设备故障检测与状态监测技术应用研究

贾常青 成广州

天辰化工有限公司 新疆 石河子 832000

摘要：随着工业4.0和智能制造的深入推进，工业机器设备的可靠性与可用性成为影响生产效率与经济效益的关键因素。故障检测与状态监测技术作为预测性维护体系的核心支撑，对于降低非计划停机损失、延长设备使用寿命具有重要意义。本文系统梳理了工业机器设备故障检测与状态监测的技术体系，分析了信号采集与处理、特征提取、故障诊断与趋势预测等关键技术环节，探讨了多源信息融合、智能诊断算法、边缘计算等前沿技术在工业场景中的应用路径，并针对当前技术应用中存在的标准化不足、数据孤岛、实时性瓶颈等问题提出了相应的发展建议。研究表明，构建“感知-分析-决策-执行”一体化的智能监测系统，是实现设备全生命周期健康管理的有效途径。

关键词：故障检测；状态监测；工业机器设备；预测性维护；智能诊断

引言

工业设备是生产系统的核心，其运行状态直接影响连续性、质量与能耗。传统定期检修易致资源浪费，事后维修则带来高昂停机损失——非计划停机每小时可造成数十万至数百万元经济损失。这推动维护策略向预测性维护演进，而故障检测与状态监测正是其核心技术支撑。技术发展已从单参数阈值判断迈向多参数融合、从时频域分析转向AI辅助诊断，并由本地监测升级为云边协同。物联网、边缘计算与深度学习提升了数据驱动方法的准确性与适应性。然而，实践中普遍存在“重硬件轻算法、重采集轻分析、重单机轻网络”等问题。因此，系统梳理技术体系、厘清关键方法的适用边界，对指导工业应用具有重要意义。

1 故障检测与状态监测的技术体系

1.1 基本概念辨析

故障检测与状态监测虽常被并提，但两者在技术内涵上存在明确区别又相互关联。状态监测是指通过传感器连续或间歇地采集设备运行参数（振动、温度、压力、电流、声发射等），实时反映设备健康状态的过程，其核心在于“状态感知”与“趋势跟踪”。故障检测则是在状态监测的基础上，通过特征分析识别异常模式，判断故障有无、类型、位置及严重程度，其核心在于“异常识别”与“故障定位”。两者共同构成了从数据采集到诊断决策的完整链条，状态监测是故障检测的数据基础，故障检测是状态监测的价值实现。

1.2 技术架构分层

工业设备故障检测与状态监测技术体系可分为五层：感知层依托加速度计、热电偶等传感器采集原始信号，其选型、安装位置与采样参数直接影响分析质量；

传输层负责数据传输，传统依赖工业以太网等有线方式，近年Zigbee、LoRa、5G等无线技术因部署灵活而广泛应用，需平衡数据量与带宽、能耗约束；计算层执行数据存储与预处理，边缘计算节点可就近提取振动幅值、温升速率等基础特征，降低云端负载与延迟；分析层为核心算法层，涵盖特征提取、降维、模式识别与寿命预测，融合传统信号处理与机器学习、深度学习方法；应用层面向运维人员，提供可视化界面、报警、维修建议及健康评估，是技术价值的最终体现。

1.3 典型设备类型与故障模式

不同设备故障模式各异，监测策略需针对性设计：旋转机械（如泵、风机）常见不平衡、不对中、轴承剥落等，主要依赖振动信号；往复机械（如压缩机、内燃机）故障包括气阀泄漏、活塞环磨损等，需结合振动、缸压与温度监测；电气设备（如电机、变压器）关注匝间短路、绝缘老化等，以电流和局部放电为主要监测参数；输送设备（如皮带机）则重点检测托辊卡滞、跑偏与断带等问题。

2 信号采集与预处理技术

2.1 传感器选型与布点策略

传感器选型需综合设备结构、故障特征频率、环境与成本等因素。加速度传感器（0.5Hz-10kHz）是旋转机械振动监测主流，可覆盖多数故障特征频率；低速重载设备（< 60rpm）宜选用速度或位移传感器。温度监测中，热电偶、热电阻适用于轴承、电机绕组等点测温，红外热像仪适合大范围扫描。布点位置与方向直接影响灵敏度：滚动轴承监测应靠近承载区，径向（水平/垂直）布置分别利于识别不平衡与松动；齿轮箱宜在啮合点附近外壳布设^[1]。布点过少易漏检早期故障，过多则增

加成本与冗余,工程上通常遵循“关键部位优先、参考点辅助”原则。

2.2 信号预处理方法

原始传感器信号常含环境噪声、电磁及工频干扰,需预处理后再提取特征。滤波是最基本手段:低通滤除高频噪声,高通消除直流漂移,带通聚焦特定频段;50Hz工频干扰可用陷波滤波器抑制。信号还需放大、偏置调整与模数转换,采样频率应为信号最高频率的5-10倍(至少2倍),并前置抗混叠滤波器以防高频成分混叠产生虚假特征。对于非平稳信号(如启停机变速过程),传统滤波效果有限,需采用时频分析方法:短时傅里叶变换通过滑动窗口追踪频率变化,小波变换则利用多尺度分解自适应平衡时间与频率分辨率。

3 特征提取与故障诊断方法

3.1 时域与频域特征分析

时域特征如均值、峰值、均方根值(RMS)、峭度、波形因子和脉冲因子等,直观反映信号特性。RMS表征振动能量,适用于磨损趋势监测;峭度对冲击敏感,轴承早期故障时常从正常值约3升至5以上;波形与脉冲因子可区分平稳与冲击性振动。频域分析通过傅里叶变换揭示能量分布:转子不平衡表现为1倍转频(1X)突出,不对中导致2X增强,齿轮磨损则体现为啮合频率边带丰富^[2]。关键在于将特征频率与设备参数(齿数、轴承型号等)关联。但传统频谱难以刻画非平稳或瞬态信号,此时包络解调技术成为滚动轴承和齿轮故障诊断的有效手段——通过希尔伯特变换提取高频共振信号的包络,还原低频冲击序列,凸显早期故障特征。

3.2 时频分析与高阶谱分析

在变转速、变速工况下,信号频率成分时变,单一频谱难以完整表征,需采用时频分析生成时间-频率-幅值三维图谱以追踪特征频率演变。短时傅里叶变换计算高效,但受窗函数限制:窄窗提高时间分辨率却牺牲频率分辨率,反之亦然。小波变换通过基函数伸缩实现多分辨率分析,在低频段具高频率分辨率、高频段具高时间分辨率,适合含突变或瞬态成分的机械信号。高阶谱分析(如双谱、三谱)可抑制高斯噪声并保留相位信息,对非线性故障(如裂纹、松动引起的摩擦)敏感,其中双谱能识别二次相位耦合现象,常与齿轮裂纹相关。但高阶谱计算量大、数据需求高,限制其在线实时应用。

3.3 传统智能诊断方法

特征提取后需建立特征到故障状态的映射,即模式识别或诊断决策。传统方法包括人工神经网络、支持向量机(SVM)、决策树与专家系统。反向传播神经网络

结构简单、应用广泛,但收敛慢且易陷局部极小值;SVM通过核函数(如径向基、多项式)在高维空间构建最优分类面,小样本下表现优异,适用于故障样本稀缺场景,但核参数需依赖交叉验证选取;决策树以if-then规则呈现,可解释性强,便于运维理解,但对特征相关性处理弱,易过拟合;专家系统将领域知识编码为规则库,适用于汽轮机知识成熟设备,但存在“知识瓶颈”和高维护成本问题。

3.4 深度学习诊断方法

深度学习推动故障诊断向端到端范式发展,可直接从原始信号或时频图中自动学习特征,减少人工特征工程依赖。卷积神经网络(CNN)在时频图分类中表现优异,二维CNN提取时频局部模式,一维CNN则直接处理时域信号、结构更紧凑;深度置信网络通过无监督预训练加微调,在轴承诊断中优于传统方法;LSTM及其变体擅长捕捉时间序列长期依赖,适用于状态预测。多标签与多任务学习可同时识别多种并发故障及严重程度;生成对抗网络(GAN)用于合成少数类样本,缓解数据不平衡。但深度学习依赖大量高质量标注数据,而工业故障样本获取成本高。迁移学习(如域对抗网络、最大均值差异匹配)将实验室等源域知识迁移到现场目标域,为小样本诊断提供有效路径。

4 状态预测与健康评估技术

4.1 剩余使用寿命预测

剩余使用寿命(RUL)预测是预测性维护的核心,旨在估计设备从当前到失效的时间。方法分为三类:基于物理模型、数据驱动及混合方法。物理模型(如Paris公式、Archard模型)外推能力强,但建模复杂且依赖大量先验知识;数据驱动方法无需机理模型,包括统计模型(维纳过程、Gamma过程)和机器学习(相关向量机、LSTM),其中维纳过程适用于非单调退化且具解析解;混合方法融合两者优势,将物理模型输出作为数据驱动的特征或约束^[3]。工程中,RUL预测需量化不确定性:点预测缺乏可信度信息,而区间预测或概率密度预测可提供失效时间范围,支撑更稳健的维修决策。

4.2 健康状态评估与健康指数构建

设备健康状态评估将多参数监测信息综合为单一的健康指数,便于运维人员快速把握设备整体状况。常用的评估框架包括层次分析法、模糊综合评价与基于马氏距离的评估。层次分析法通过专家打分构建判断矩阵确定指标权重,主观性较强但操作简便。模糊综合评价通过隶属度函数处理指标边界模糊的问题,适合描述“轻微磨损”“中度磨损”等定性状态。健康指数的时间序

列反映了退化轨迹，可以使用隐马尔可夫模型或状态空间模型进行滤波与预测。健康指数构建的关键挑战在于如何将不同量纲、不同物理意义的监测指标（如振动幅值、温度、电流）合理融合，以及如何设定不同工况下的基准健康值。

4.3 阈值设定与报警策略

合理设定报警阈值是平衡漏报与误报的关键。传统固定阈值（如ISO 10816）简单但难以适应工况变化和设备的差异；自适应阈值基于正常数据建立统计基线，超限（如3倍标准差）即报警；针对非平稳工况，残差阈值法通过建模输入参数（转速、负载）与监测指标的关系，以预测残差判断异常^[4]。多参数联合报警可显著降低误报：如仅振动升高可能为传感器松动，若温度同步异常则故障可信度高。工程中还采用报警延迟策略（连续多点超限才报警）和分级报警（预警、一级、二级）提升系统可用性与可靠性。

5 系统集成与应用挑战

5.1 多源信息融合技术

单一传感器信息有限，多源信息融合通过整合振动、温度、电流、声发射、油液分析等多维数据，提升诊断鲁棒性与准确性。融合可在数据层、特征层或决策层进行：数据层融合直接合并原始信号，信息保留最完整但要求高同步性；特征层融合最为常用，将各传感器提取的特征拼接后输入分类器；决策层融合则结合各传感器独立诊断结果，采用投票、贝叶斯推理或D-S证据理论，后者能显式处理不确定性，通过合成基本概率分配函数提升置信度。尤其在齿轮箱、发动机等设备中，振动监测捕捉早期冲击故障，油液分析（如光谱、铁谱）提供磨损颗粒的成分与形态信息，二者互补，显著增强故障识别能力。

5.2 边缘计算与云边协同

工业设备监测产生的高频数据（如振动信号采样率可达50kHz以上）若全部上传至云端，将面临带宽瓶颈与实时性挑战。边缘计算架构将数据预处理、特征提取与初步诊断任务部署在靠近数据源的边缘节点（如智能传感器、边缘网关），仅将诊断结果与少量关键数据上传至云端。这一架构的典型延迟可控制在毫秒级别，满足高速设备的实时报警需求。云边协同机制需要解决任务动态调度与模型增量更新的问题。云端训练的深度学习

模型可以定期下发至边缘节点，边缘节点积累的本地数据则可用于模型微调，形成闭环优化。联邦学习作为隐私保护的分布式学习框架，允许多个边缘节点在不共享原始数据的前提下协同训练全局模型，适用于跨工厂、跨区域的设备监测网络。

5.3 当前面临的主要挑战

尽管技术日趋成熟，工业故障检测与状态监测仍面临多重挑战：一是标准化不足，传感器接口、数据格式、通信协议及特征定义缺乏统一，推高集成成本，阻碍“即插即用”；二是数据孤岛普遍，设备制造商、用户与第三方的数据壁垒限制了跨设备大规模学习；三是高端设备故障率低，小样本甚至零样本问题突出，制约监督学习应用；四是深度学习模型可解释性差，“黑箱”决策难以赢得运维人员信任；五是嵌入式系统受计算与存储资源限制，对算法轻量化和实时性提出更高要求。

6 结语

工业设备故障检测正从单参数报警转向多源融合智能诊断，从定期采样迈向连续在线监测，并由孤立系统发展为云边协同网络。本文梳理了涵盖感知、传输、计算、分析与应用的完整技术架构，指出不同方法适用场景各异：包络谱与峭度适用于机理清晰的旋转机械；深度学习与多源融合则在复杂系统中优势显著。边缘计算缓解实时性与带宽压力，迁移学习与GAN助力小样本诊断。未来，数字孪生将实现故障仿真与维护验证，知识图谱提供语义推理支持，可解释AI增强模型可信度。随着标准化与开放生态推进，该技术将从“奢侈品”变为智能工厂标配。

参考文献

- [1]宁宁.面向工业设备信号处理和故障诊断的边缘智能控制[J].机械工业标准化与质量,2025,(12):32-35.
- [2]李世豪,曾铨,缪巍巍,等.基于时序知识图谱的工业物联网设备故障态势预测[J].太赫兹科学与电子信息学报,2025,23(10):1060-1066+1073.
- [3]朱曦.面向工业互联网的联网设备故障检测分析技术研究[D].南京邮电大学,2024.DOI:10.27251/d.cnki.gnjdc.2024.000350.
- [4]邵汉舒.基于设备管理工业物联网的设备异常监测与故障诊断方法研究[J].物联网技术,2025,15(16):87-90+94.