

数据驱动的设备风险动态预警与精准管控机制的创新

张林波, 张煜东

甘肃银光化学工业集团有限公司, 甘肃 白银

收稿日期: 2026年8月2日; 录用日期: 2026年8月31日; 发布日期: 2026年9月14日

摘要

针对高温、高压、连续生产工况下化工旋转设备风险感知滞后、运维决策缺乏数据支撑、静态阈值难以捕捉早期微弱劣化的问题, 文章提出了一种数据驱动的设备风险动态预警与精准管控机制, 并以机理-数据混合驱动的故障诊断作为技术核心。该机制以振动在线监测为核心、融合多源运行数据, 构建“感知-诊断-预警-管控-反馈”的闭环; 在特征提取环节提出“机理频带引导+包络解调”的优化策略, 以故障特征频率为先验进行自适应频带聚焦, 抑制强背景噪声与工艺扰动; 在诊断环节构建机理模型与机器学习并行、由证据加权融合的双通道模型, 兼顾早期微弱故障的检出率与结论的可解释性; 在此基础上完成风险动态分级预警, 并将预警与故障原因、剩余寿命及分级维修建议绑定, 实现由被动维修向主动预控的精准管控转变。以某大型化工企业572台关键设备、1463个测点的实测数据验证表明: 故障诊断准确率由基线的76.2%提升至93.8%, 早期预警平均提前量由不足24小时提升至约168小时, 非计划停机率下降62.5%, 年度维修成本下降28.4%。研究可为流程工业设备的预测性维护提供可复用的方法与量化依据。

关键词

风险动态预警, 精准管控, 数据驱动, 机理-数据混合模型, 特征提取, 故障诊断

Innovation in Data-Driven Device Risk Dynamic Early Warning and Precise Control Mechanisms

Linbo Zhang, Yudong Zhang

Gansu Yinguang Chemical Industry Group Co., Ltd., Baiyin Gansu

Received: August 2, 2026; accepted: August 31, 2026; published: September 14, 2026

文章引用: 张林波, 张煜东. 数据驱动的设备风险动态预警与精准管控机制的创新[J]. 传感器技术与应用, 2026, 14(5): 828-839. DOI: 10.12677/jsta.2026.145080

Abstract

To address the issues of delayed risk perception, lack of data-driven support for operation and maintenance decisions, and the inability of static thresholds to capture early-stage weak degradation in chemical rotating equipment under high-temperature, high-pressure, and continuous production conditions, this paper proposes a data-driven mechanism for dynamic risk early warning and precise management and control, with a mechanism-data hybrid-driven fault diagnosis as its technical core. Centered on online vibration monitoring and integrating multi-source operational data, the mechanism establishes a closed-loop framework of “perception-diagnosis-early warning-control-feedback”. In the feature extraction stage, an optimized strategy of “mechanism-informed frequency band guidance + envelope demodulation” is proposed, which utilizes fault characteristic frequencies as prior knowledge to achieve adaptive frequency band focusing, thereby suppressing strong background noise and process disturbances. In the diagnosis stage, a dual-channel model is constructed, in which a mechanism-based model and a machine learning model operate in parallel and are integrated through evidence-weighted fusion, thereby reconciling the detection rate of early-stage weak faults with the interpretability of diagnostic conclusions. On this basis, dynamic risk grading and early warning are accomplished, with warning information linked to fault causes, remaining useful life prediction, and graded maintenance recommendations, thus enabling the transition from passive maintenance to active pre-control and precise management. Validation using measured data from 572 key equipment units and 1,463 measurement points at a large chemical enterprise demonstrates that the fault diagnosis accuracy improved from a baseline of 76.2% to 93.8%, the average advance time of early warning increased from less than 24 hours to approximately 168 hours, the unplanned downtime rate was reduced by 62.5%, and the annual maintenance cost decreased by 28.4%. This research provides a replicable methodology and quantitative basis for the predictive maintenance of process industry equipment.

Keywords

Dynamic Risk Early Warning, Precision Control, Data-Driven, Mechanism-Data Hybrid Model, Feature Extraction, Fault Diagnosis

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在工业 4.0 与智能制造推动下, 设备运维正由传统的被动式、计划性维修向数据驱动的预测性维护转变。石油化工等流程工业的关键旋转设备(如压缩机、反应釜搅拌机、各类泵机等)长期运行于高温、高压、易燃易爆的连续工况, 突发故障不仅导致非计划停机与经济损失, 更可能引发重大安全事故。因此, 实现状态实时感知、故障早期识别与风险精准管控是核心问题。

现有方法主要分为两类: 一是基于物理机理的诊断方法, 结论可解释性强, 但对复杂工况下的微弱早期故障与耦合故障适应性有限; 二是数据驱动方法, 借助机器学习/深度学习挖掘故障模式, 泛化能力强, 但普遍存在“黑箱”特性、可解释性差、对标注样本依赖大等问题。基于此, 本文提出了一种数据驱动的设备风险动态预警与精准管控机制, 以机理-数据混合驱动故障诊断为核心, 主要贡献如下:

1) 提出“机理频带引导 + 包络解调”的优化特征提取方法, 以故障特征频率为先验进行自适应频带聚焦与包络解调, 显著提升强噪声下早期微弱故障特征的信噪比;

2) 构建机理与数据模型并行、由证据加权融合的双通道诊断模型, 在提升检出率的同时保证结论的可解释性;

3) 建立“感知-诊断-预警-管控-反馈”闭环, 将预警与故障原因、剩余寿命及维修建议绑定, 实现由被动维修向主动预控转变;

4) 基于某大型化工企业实测数据, 从诊断准确率、预警提前量、停机率及维修成本等维度系统验证了该机制的有效性。

2. 相关工作

2.1. 预测性维护

预测性维护(Predictive Maintenance, PdM)旨在依据设备实时运行状态预测其性能退化趋势与剩余寿命(Remaining Useful Life, RUL), 从而在恶性故障发生前进行精细化的有计划干预, 是继事后维修(Corrective Maintenance)、定期维修(Preventive Maintenance)之后的第三代维修范式。围绕状态监测(Condition Monitoring)、异常检测(Anomaly Detection)、健康评估与维修决策优化, 学界与工业界已开展了大量研究[1]。在电力、冶金、轨道交通、烟草、煤矿等标准化程度较高或机械结构相对独立的行业中, PdM 已形成了较为成熟的落地应用[2] [3]。

然而, 现有的预测性维护范式在面对高危化工工艺、极端服役环境时仍面临巨大挑战。化工旋转设备(如大型离心压缩机、高压泵、反应器搅拌轴等)往往处于高温、高压、强腐蚀、连续不间断运行的复杂工况中。在这类场景下: 故障样本天然稀缺, 出于安全与生产效益考虑, 设备极少被允许运行至全寿命周期的完全失效状态, 导致“全生命周期退化数据”极度匮乏; 试错成本极高, 任何误报引发的非计划停机或漏报导致的恶性事故, 都会带来不可估量的经济损失与安全环保灾难[4]。

因此, 如何在保证模型高可解释性(Interpretability)的前提下, 显著提升弱特征、早期故障的预测能力, 是当前化工设备 PdM 领域亟待深入解决的核心瓶颈。

2.2. 基于机理的故障诊断

基于机理的方法以旋转机械的动力学行为和振动机理为基础。通过建立转子动力学模型、有限元模型或解析退化方程, 推导并识别故障特征频率(如轴承内圈/外圈/滚动体/保持架特征频率、齿轮听合频率、转子不平衡/不对中/松动的谐波与分频规律), 进而实现故障的精准定位与原因追溯[5]。此类方法具有物理意义明确、因果关系清晰、可解释性强的天然优点, 在设备全生命周期的初始设计与标准工况的故障机理分析中发挥着不可替代的作用。

然而, 在工业实际(特别是化工机械)中, 该方法面临三大难以调和的实用化困境: 信号淹没与强噪声, 化工设备常受到气蚀、流体激振、复杂管路传导等多源背景噪声的强烈干扰, 微弱的早期故障特征频率极易被淹没; 多故障耦合与变工况, 实际运行中常出现“不平衡耦合轴承磨损”等复合故障, 且生产负荷频繁调整, 导致解析机理模型的边界条件实时剧烈变化; 高建模壁垒, 该方法高度依赖精确的结构参数与资深专家的先验规则, 面对复杂大型系统时机理建模往往陷入“维数灾难”或参数失真。

2.3. 基于数据驱动的故障诊断

随着现代工业物联网(IIoT)与传感器技术的普及, 数据驱动的方法迎来了爆发式增长。该类方法以支持向量机(SVM)、逻辑回归、K 近邻(KNN)、随机森林、XGBoost 等经典机器学习算法, 以及卷积神经网络(CNN)、循环神经网络(RNN)、Transformer 等深度学习模型为代表。通过端到端(End-to-End)地从历史监测数据中自动挖掘、学习复杂的故障特征模式, 展现出了极强的非线性拟合能力与泛化性能[6]。

尽管数据驱动方法在公开标准数据集上取得了接近 100% 的分类准确率, 但在面对实际化工高危设备

时, 其固有的“黑盒”属性与静态特征挖掘方式带来了严重的工程应用隐患: 不可解释性与决策风险, 深度学习模型的内部决策机制缺乏物理逻辑支撑, 导致其诊断结果难以提供令人信服的机理解释; 缺乏动态演化评估, 现有的诸多数据驱动模型倾向于“静态分类”, 难以对设备风险进行时序上的动态演化推演与前瞻性预警; 严重的过拟合倾向, 在化工高危设备“正常数据多、故障样本极稀缺”的严重类不平衡条件下, 模型极易陷入局部最优、假阳性或假阴性高发的泥潭。

2.4. 机理 - 数据混合方法与本文定位

为了打破上述“机理模型由于简化而精度不足”与“数据模型由于黑盒而无法信任”的学术双重困境, 近年来机理 - 数据混合(Physics-Informed/Hybrid)建模逐渐成为故障诊断与动力学系统健康管理(PHM)领域的前沿研究热点。目前, 主流的混合策略主要分为两类: 一是数据驱动的机理修正, 即利用数据模型拟合传统机理方程中的未建模残差; 二是物理知识约束的数据模型, 如物理信息神经网络(PINN), 通过在损失函数中引入微分方程约束, 或在网络输入端注入领域知识[7]。

然而, 现有的混合方法在化工旋转设备的实际落地中, 依然缺乏将“故障诊断”转化为“风险主动防控”的闭环机制, 主要体现在: “预警”的动态感知不足, 多数研究仍停留在静态的多源特征融合阶段, 未能将机理先验与时序演化特征深度结合; “管控”的精准量化缺失, 现有的诊断输出通常流于单一的概率分布, 缺乏机理通道与数据通道在冲突时的量化融合决策机制。

有鉴于此, 本文紧扣“数据驱动的设备风险动态预警与精准管控机制”这一核心主题, 面向化工旋转设备提出了一种机理先验引导与证据加权融合的双通道动态预警与精准管控方法。本文的创新与定位主要体现在: 机理引导的动态风险特征空间重构, 利用旋转机械动力学先验对特征提取阶段进行强引导, 确保时序动态预警特征具有明确的物理敏感性; 证据加权融合的双通道精准管控机制, 引入证据理论将机理诊断通道的“确定性因果关系”与数据驱动通道的“概率性模式识别”进行深度多源信息融合; 全流程闭环的工业实测试验, 构建了完整的动态预警与精准管控闭环量化评估体系, 并在真实的化工高危旋转设备实测数据集上进行了验证。

3. 研究方法

3.1. 总体框架

图1: “感知—特征—诊断—预警—反馈”闭环整体流程




Figure 1. The “Perception-Feature-Diagnosis-Alerting-Feedback” closed-loop workflow
图 1. “感知 - 特征 - 诊断 - 预警 - 反馈”的闭环整体流程

构建“感知-特征-诊断-预警-反馈”的闭环：由多源传感器与边缘计算节点完成设备状态的高频连续感知；经优化特征提取获得高信噪比的故障敏感特征；由机理-数据双通道模型进行诊断与融合；依据诊断结论与退化趋势进行风险动态分级与预警；维修反馈再回流用于模型迭代。整体流程如图 1 所示：先获取机器状态数据，送入故障诊断模块进行信号处理与特征提取，由机理通道与数据通道并行判别并融合，若判定存在故障，则输出故障类型、故障部位与风险等级至监控中心/报警终端。

状态监测软件采用 B/S 架构与微服务设计，支持私有化、云端及 Docker 容器化部署，以适应不同工业网络环境。

3.2. 状态监测与数据采集

本次采用有线方式，在机组振动显著部位安装振动传感器，利用在线监测系统融合既有监测数据，并依据设备运行工况设定合理的数据采集策略，以获取可有效用于故障分析与定位的振动信号。在此基础上，依托智能报警机制实时识别设备运行状态的异常。根据机械结构及运转特性，旋转机械在长期运行过程中常见的故障类型如表 1 所示。

Table 1. Common mechanical fault types of rotating machinery

表 1. 旋转机械常见机械故障类型

故障类型	故障描述
轴承损伤	内圈、外圈、滚动体、保持架磨损、点蚀、剥落等
松动	轴承内圈与转轴配合松动；轴承外圈与轴承座配合松动，基础松动、其他零部件松动
主轴、叶轮	主轴不平衡、主轴偏心，叶轮不平衡
不对中	电机输出轴与负载输入轴(皮带轮)，因安装或使用问题导致两轴角度/平行不对中
减速机、滚筒磨损	因加工精度、工况变化、冲击等原因引起的减速机、滚筒磨损等
齿轮箱	齿轮听合故障

振动测点选择标准：近距、刚性支撑、安全。轴承是机器的主要承载部件，典型机械故障产生的振动信号最终都会传递至具有刚性支撑的轴承座位置。虽然振动幅值在传递过程中会有所衰减，但故障特征频率不变。因此，将传感器安装于轴承座等刚性支撑处，可同时监测轴承缺陷及转子不平衡、齿轮故障等典型机械故障。硬件设施如图 2 所示。



Figure 2. Intelligent high-speed data acquisition module and temperature/vibration sensor
图 2. 智能高速数采模块和温振传感器

该方案核心优势如下:

边缘侧高性能感知: 依托边缘计算节点, 硬件性能严格遵循奈奎斯特采样定理, 确保原始信号的完整性与高速传输; 兼容 Modbus、OPC 等异构工业协议, 具备大规模高频并发监测能力。

机理与数据双驱动: 构建“机理模型 + 数据驱动”的融合算法架构, 实现对设备性能退化趋势与早期微弱故障征兆的精准辨识。系统创新融合故障根因分析、风险传播建模及剩余使用寿命(RUL)预测, 输出分级精准的运维决策支持。

数字孪生主动运维: 打造“感知 - 诊断 - 决策 - 优化”的自适应闭环体系, 利用数字孪生技术推动设备管理由被动响应向主动免疫与精益治理转型, 夯实工业装备的本质安全。

3.3. 优化的特征提取方法

针对化工旋转设备早期故障特征微弱且易被强噪声淹没的难题, 提出“机理频带引导 + 包络解调”的优化提取方法。该方法融合机理先验知识与谱峭度准则, 自适应锁定共振解调频带, 通过包络解调从高频载波中还原故障信息, 有效克服低信噪比干扰, 精准凸显早期故障特征。整体流程如图 3 所示, 涵盖机理先验计算、自适应频带聚焦、包络解调与特征向量构建四个步骤。




图3: 机理频带引导+包络解调优化特征提取方法流程图

Figure 3. Flowchart of the optimized feature extraction process based on “mechanism frequency band guidance + envelope demodulation”

图 3. “机理频带引导 + 包络解调” 的优化特征提取流程图

步骤 1: 机理先验计算。依据旋转机械振动机理, 利用转频、几何尺寸等参数计算轴承与齿轮的故障特征频率(式(1)~(5)), 特征频率计算主要符号说明见表 2。以此为中心构建候选故障频带集合 BB(式(6)), 为后续频带搜索提供机理约束, 避免盲目搜索。

$$f_{FTF} = \frac{1}{2} f_r \left(1 - \frac{d}{D} \cos \alpha \right) \quad (1)$$

$$f_{BPFO} = \frac{Z}{2} f_r \left(1 - \frac{d}{D} \cos \alpha \right) \quad (2)$$

$$f_{BPF1} = \frac{Z}{2} f_r \left(1 + \frac{d}{D} \cos \alpha \right) \quad (3)$$

$$f_{BSF} = \frac{D}{2d} f_r \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right] \quad (4)$$

$$f_m = Z f_r \quad (5)$$

$$B = \{ f_{c,k} - \Delta, f_{c,k} + \Delta | k = 1, 2, \dots, K \} \quad (6)$$

Table 2. Main symbol definitions for characteristic frequency calculation
表 2. 特征频率计算主要符号说明

符号	物理含义
f_r	转频(轴的旋转频率), Hz
Z	轴承滚动体个数
d, D	滚动体直径与轴承节圆直径, mm
α	轴承接触角, °
z	齿轮齿数
$f_{c,k}$	第 k 个潜在故障的机理特征频率, Hz
Δ	候选故障频带的半带宽, Hz

步骤 2: 自适应频带聚焦。故障冲击往往激发轴承座 - 传感器传递路径上的结构高频共振, 故障信息以“调制”形式驻留于共振频带。为定位该解调频带, 本文以谱峭度(Spectral Kurtosis, SK)作为对冲击敏感性的度量[8]。峭度反映信号概率分布相对高斯分布的尖峰程度, 定义如式(7)所示:

$$K = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^2} \quad (7)$$

对信号作短时傅里叶变换 $X(t, f)$, 其谱峭度定义为各频率成分包络的四阶归一化累积量, 如式(8)所示, SK 值越大表明该频率处的冲击性越强:

$$SK(f) = \frac{\left\{ \left| X(t_f) \right|^4 \right\}}{\left\{ \left| X(t_f) \right|^2 \right\}^2} - 2 \quad (8)$$

在候选频带集合 B 内, 以谱峭度最大为准则自适应确定最优解调中心频率与带宽, 如式(9)所示, 并据此对原始信号进行带通滤波, 将能量聚焦到承载故障冲击的频带, 抑制无关频段噪声:

$$(f^*, B^*) = \arg \max_{f, B} SK(f; B) \quad (9)$$

步骤 3: 包络解调。对带通滤波所得信号 $x_f(t)$ 进行希尔伯特变换, 得到其正交分量, 如式(10)所示:

$$\hat{x}(t) = \frac{1}{n} \int_{-\infty}^{+\infty} p_x V_x \left(\int_{-\infty}^{+\infty} x f(\tau) d\tau \right) d\tau \quad (10)$$

构造解析信号并取其模, 即得振动信号的包络 $A(t)$, 如式(11)所示:

$$A(t) = |x_f(t) + j\hat{x}(t)| = \sqrt{x_f^2(t) + \hat{x}^2(t)} \quad (11)$$

包络剥离高频共振载波, 保留随故障冲击变化的低频调制信息。仿真外圈故障信号对比(图 4)表明: 原始频谱中故障频率被噪声淹没, 而包络谱中 BPFOBPFO 及其谐波清晰可辨, 验证了频带聚焦与包络解调对早期微弱特征的增强效果。




Figure 4. Effect of sub-band focusing and envelope demodulation (simulated outer-race fault)

图 4. 带通聚焦与包络解调效果对比(仿真外圈故障)

步骤 4: 特征向量构建。综合时域统计特征与包络谱故障特征频率幅值, 构建兼具物理含义的特征向量。常用时域无量纲/有量纲指标的定义与物理意义如表 3 所示。

Table 3. Definitions and physical meanings of the main time-domain characteristic parameters

表 3. 主要时域特征参数定义与物理意义

参数	物理意义
有效值 x_{rms}	反映振动能量水平
峰值 x_p	反映瞬时最大冲击
峭度 K	对早期冲击性故障敏感
峰值指标 C	衡量冲击的相对强度
脉冲指标 I	对冲击性故障敏感
裕度指标 L	对磨损类故障敏感

记包络谱上第 k 个故障特征频率及其谐波的幅值为 $A_{\{c,k\}}$, 将时域指标与包络谱特征拼接, 得到最终特征向量, 如式(12)所示:

$$\mathbf{v} = [x_{rms}, x_p, K, C, I, L, A_{c,1}, A_{c,2}, \dots, A_{c,K}]^T \quad (12)$$

本方法优势体现在三方面: ① 以机理特征频率为先验缩小频域搜索空间; ② 以谱峭度自适应聚焦共振频带; ③ 经包络解调放大微弱冲击成分。消融实验表明, 相较原始频谱特征, 早期故障召回率由 70.4% 提升至 90.2%, 误报率由 15.1% 降至 6.3%, 证实了方法的有效性与优越性。

3.4. 机理 - 数据混合诊断模型

在 3.3 节所得高信噪比特征基础上, 本文构建机理与数据并行诊断通道, 并以证据加权融合输出最

终结论, 兼顾诊断的检出率与可解释性, 总体架构如图 5 所示。

1) 机理诊断通道。将包络谱显著峰值频率与机理特征频率库(轴承、齿轮、皮带、叶轮、电机等)逐一匹配。设故障类别 c 的理论特征频率为 f_c^{th} 、实测峰值频率为 f_c^{obs} , 当满足式(13)的相对容差条件时判定命中, 其中 ε 为容差系数, 用于容纳转速波动与频率估计误差:

$$\left| f_c^{obs} - f_c^{th} \right| \leq \varepsilon f_c^{th} \quad (13)$$

以命中特征频率及其各阶谐波的相对能量占比作为该类别的可解释置信度证据 $m_1(c)$, 如式(14)所示, 分子为命中谐波幅值之和, 分母为对应频带总能量, H 为参与统计的谐波阶数:

$$m_1(c) = \frac{\sum_{h=1}^H A(hf_c^{th})}{\sum_{f \in B_c} E(f)} \quad (14)$$




Figure 5. Architecture of the mechanism-data dual-channel hybrid diagnosis

图 5. 机理 - 数据双通道混合诊断架构

2) 数据诊断通道。以特征向量 v 为输入, 采用对小样本鲁棒、可给出特征重要度的集成学习算法(随机森林/XGBoost)建立分类器。为增强数据通道的可解释性, 按各特征在所有树节点分裂中带来的基尼不纯度下降量统计特征重要度, 如式(15)所示, 据此可回溯诊断结论最依赖的物理特征(如包络谱 BPFO 幅值、峭度等):

$$\text{Imp}(v_j) = \frac{1}{B} \sum_{b=1}^B \sum_{t \in T_b} \Delta \text{Gini}(t) \cdot 1 \left[s(t) = v_j \right] \quad (15)$$

3) 证据加权融合。对两通道证据按可信度加权融合, 得到类别 c 的综合得分, 如式(16)所示; 权重依据历史验证集上各通道的诊断准确率动态标定, 使表现更优的通道获得更大权重, 如式(17)所示:

$$S(c) = w_1 m_1(c) + w_2 m_2(c), w_1 + w_2 = 1 \quad (16)$$

$$w_i = \frac{\text{acc}_i}{\text{acc}_i + \text{acc}_2}, i = 1, 2 \quad (17)$$

最终故障类别由综合得分最大者决策, 如式(18)所示。同时以机理证据对数据结论进行一致性校验——当两通道判别结果冲突时, 优先输出物理可解释的机理结论并触发人工复核, 从而在提升早期故障检出率的同时, 有效抑制数据模型的“黑箱”误报:

$$\hat{c} = \arg \max_c S(c) \quad (18)$$

3.5. 风险动态分级与预警

依据 ISO 10816-3 标准与融合诊断置信度, 系统对设备进行动态风险分级。以速度有效值超 4.5 mm/s 为例, 系统触发预警并自动提升点检频次, 安排计划停机检修; 若指标进一步恶化则升级为报警, 提示立即维修。同时, 预警信息深度融合故障原因、风险传播路径及剩余寿命预估, 为用户提供分级、精准的维修决策建议。

4. 实践与结果

4.1. 数据来源

基于银光集团 572 台设备、1463 个测点的在线监测数据进行验证, 以该企业实施本方法前的“人工定期点检 + 事后维修”管理模式作为评估基线, 对比周期为实施前后各 12 个月。

4.2. 评估指标与总体成效

选取故障诊断准确率、早期预警平均提前量、非计划停机率、平均无故障时间(MTBF)、误报率与年度维修成本作为评估指标。实施前(基线)与实施后的量化对比如表 4 所示。

Table 4. Comparison of key performance indicators before (baseline) and after implementation

表 4. 实施前(基线)与实施后关键性能指标对比

性能指标	实施前(基线)	实施后	改进幅度
故障诊断准确率	76.2%	93.8%	+17.6 个百分点
早期预警平均提前量	<24 h	≈168 h	约 7 倍
非计划停机率	3.2 次/(台·年)	1.2 次/(台·年)	-62.5%
平均无故障时间 MTBF	2760 h	4120 h	+49.3%
故障误报率	18.5%	6.3%	-12.2 个百分点
年度维修成本(相对值)	100	71.6	-28.4%

实施后故障诊断准确率从 76.2%升至 93.8%, 早期预警平均提前量由不足 24 h 提升至约 168 h, 非计划停机率下降 62.5%, MTBF 提高 49.3%, 误报率从 18.5%降至 6.3%, 年度维修成本降低 28.4%, 验证了方法的有效性和经济价值。

4.3. 特征提取方法的消融对比

在相同分类器下, 本文提出的“机理频带引导 + 包络解调”特征提取方法分别取得了 93.8%的准确率、90.2%的早期故障召回率及 6.3%的误报率, 均显著优于基于原始频谱特征(81.5%、70.4%、15.1%)和基于时域统计特征(78.9%、66.8%、17.3%)的结果, 证明机理引导对低信噪比特征可分性的提升作用, 具体见表 5。

Table 5. Diagnostic performance comparison of different feature extraction schemes

表 5. 不同特征提取方案的诊断性能对比

特征提取方案	准确率	早期故障召回率	误报率
(a) 原始频谱特征	81.5%	70.4%	15.1%
(b) 仅时域统计特征	78.9%	66.8%	17.3%
(c) 本文方法	93.8%	90.2%	6.3%

4.4. 案例分析

以某 1#粉体泵为例, 其在线监测总貌可实时显示各测点振动与温度。系统监测到泵体端振动由正常水平逐步升高至 9.48 mm/s (超过 ISO 10816-3 预警阈值), 触发分级预警。对该测点原始波形进行采集与智能处理, 得到振动趋势图、时域波形图与包络频谱图, 如图 6 所示。




Figure 6. Vibration trend, time-domain waveform and envelope spectrum (core analysis section)
图 6. 设备振动趋势、时域波形与包络频谱(核心论证部分)

双通道融合诊断结论为: 泵端轴承保持架故障, 建议检查润滑, 如图 7 所示。拆机验证发现轴承存在点蚀与裂纹, 与诊断结论一致; 检修后振动回落, 避免了连锁停产损失。



Figure 7. Intelligent diagnostic result (core analysis section)
图 7. 智能诊断结果(核心论证部分)

5. 讨论

机理先验缓解了小样本强噪声下的过拟合与误报, 数据通道弥补了机理规则对复杂耦合故障适应性的不足, 证据融合实现“检出率 - 可解释性”平衡。目前, 权重标定依赖历史数据, 工况漂移时需在线自适应; 对象以旋转/往复设备为主, 对慢变过程设备需融合更多工艺机理; 剩余寿命预测受退化样本量限制。未来将引入迁移学习和物理约束深度模型提升泛化能力。

6. 结论

本文提出并验证了一种数据驱动的设备风险动态预警与精准管控机制, 其技术核心为机理 - 数据混合驱动的故障诊断: 以“机理频带引导 + 包络解调”的优化特征提取提升低信噪比下早期故障特征的可分性; 以机理与数据双通道证据加权融合兼顾诊断的检出率与可解释性; 并据此建立“感知 - 诊断 - 预警 - 管控 - 反馈”的闭环, 实现风险动态分级预警与精准维修管控。在某大型化工企业 572 台设备、1463 个测点上的实试验证表明, 相较实施前基线, 故障诊断准确率由 76.2% 提升至 93.8%, 早期预警平均提前量由不足 24 小时提升至约 168 小时, 非计划停机率下降 62.5%, 年度维修成本下降 28.4%。该机制推动设备运维由被动应付、粗放管控向主动预控、精益治理转变, 可为流程工业设备的风险管控与预测性维护提供可复用的方法与量化依据。未来将进一步融合工艺机理与深度模型, 扩展至更广泛的化工设备类型与剩余寿命预测场景。

参考文献

- [1] Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N. and Nandi, A.K. (2020) Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap. *Mechanical Systems and Signal Processing*, **138**, Article ID: 106587. <https://doi.org/10.1016/j.ymssp.2019.106587>
- [2] 杨一晴, 马宏伟, 樊红卫, 等. 矿井主通风机振动在线监测与故障诊断系统[J]. 煤矿机械, 2019, 40(12): 161-163.
- [3] 王昱, 孙超, 林焕楚, 等. 烟草行业大功率电机在线状态监测技术与维修应用[J]. 中国设备工程, 2022(18): 18-20.
- [4] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械装备故障的智能诊断与自愈化研究[J]. 机械工程学报, 2018, 54(5): 94-104.
- [5] Randall, R.B. and Antoni, J. (2011) Rolling Element Bearing Diagnostics—A Tutorial. *Mechanical Systems and Signal Processing*, **25**, 485-520. <https://doi.org/10.1016/j.ymssp.2010.07.017>
- [6] 邵思羽. 基于深度学习的旋转机械故障诊断方法研究[D]: [博士学位论文]. 南京: 东南大学, 2019.
- [7] Willard, J., Jia, X., Xu, S., et al. (2020) Integrating Scientific Knowledge with Machine Learning for Engineering and Environmental Systems. arXiv:2003.04919.
- [8] Antoni, J. (2007) Fast Computation of the Kurtogram for the Detection of Transient Faults. *Mechanical Systems and Signal Processing*, **21**, 108-124. <https://doi.org/10.1016/j.ymssp.2005.12.002>