

化工自动化仪表故障诊断与预测性维护技术研究

王陈阳

山西焦化集团有限公司 山西 临汾 041606

摘要: 在化工生产大型化、连续化、智能化趋势下, 自动化仪表作为工艺“感官”, 其可靠性直接关乎系统安全与效率。传统定期检修与事后维修模式已难以满足长周期高可靠运行需求, 常因非计划停车造成重大损失。本文聚焦仪表全生命周期健康管理, 构建从故障诊断到预测性维护(PdM)的技术框架: 首先分析典型故障模式, 涵盖传感器漂移、电子老化、机械磨损及环境侵蚀等; 继而提出融合机理分析与数据驱动的多层次诊断方法, 包括基于模型、信号处理和知识规则等路径; 进而系统阐述PdM核心技术——多源数据融合、健康指标(HI)构建、剩余使用寿命(RUL)预测及维护决策优化; 最后展望数字孪生、边缘计算与人工智能如何赋能下一代智能运维体系。本研究旨在为化工企业提供理论完备、技术先进且可落地的仪表健康管理方案, 推动运维模式向本质安全与卓越运营转型。

关键词: 化工自动化仪表; 故障诊断; 预测性维护

引言

化学工业具有高温、高压、易燃易爆、有毒有害等特点, 对安全与连续性要求极高。自动化仪表作为感知工艺状态的“感官”, 其数据是控制系统运行、操作决策及能效管理的基础。一旦故障, 轻则影响质量与能耗, 重则引发非计划停车甚至安全事故。传统以固定周期执行的预防性维护(PM)存在“过维护”或“欠维护”问题: 前者浪费资源且可能引入新风险, 后者则难以及时发现性能劣化, 隐患突出。随着工业4.0推进, 预测性维护(PdM)成为新范式, 通过实时监测与分析, 精准预判故障, 在恰当时机干预, 实现“该修才修, 修必修好”。然而, 化工仪表种类多、原理异、环境干扰强, 高质量数据获取难, 且需从多源异构数据中提取有效特征并构建可靠模型, 技术门槛高。本文旨在系统梳理故障诊断与PdM关键技术, 构建完整理论与技术框架, 为化工仪表智能化运维提供支撑。

1 化工自动化仪表的典型故障模式与机理

1.1 按故障表现形式分类

化工自动化仪表的故障可以从其外在表现进行初步分类。完全失效是最直观的故障形式, 表现为仪表输出信号丢失(如电流回路断开)、输出恒定不变(如卡在量程上限或下限)或输出剧烈振荡, 导致控制系统完全失去对该参数的监控。精度漂移则更为隐蔽和普遍, 指仪表的测量值虽然随被测变量变化, 但其偏差超出了允许的误差范围。这种漂移可能是缓慢的、渐进式的(如传感器老化), 也可能是阶跃式的(如受到强冲击或电磁干扰后)。响应迟缓是指仪表对被测变量的真实变化反应滞后, 动态性能下降, 这在快速变化的控制回路中尤为致

命, 可能导致系统不稳定。此外, 还有间歇性故障, 即故障现象时有时无, 给诊断和定位带来极大困难。

1.2 按故障根源机理分类

深入理解故障机理是实现有效诊断与预测的基础。按根源可分为四类: 一是传感元件老化与漂移, 如热电偶/热电阻因高温再结晶或污染导致特性偏移, 压力变送器隔离膜片疲劳影响线性度, pH电极玻璃膜老化造成响应斜率下降和零点漂移。二是电子部件失效, 包括电路板、放大器、A/D转换器等因热积累、电压波动、静电放电(ESD)或制造缺陷引发参数漂移、功能异常甚至烧毁^[1]。三是机械部件磨损与堵塞, 典型如涡街流量计旋涡发生体被冲刷磨损, 质量流量计振动管因结垢或腐蚀改变固有频率, 调节阀阀芯/阀座磨损导致内漏, 孔板锐边磨钝影响流出系数。四是环境因素侵蚀, 化工现场尤为突出: 强腐蚀介质可穿透密封侵蚀内部元件; 高湿或雨水引发短路或绝缘劣化; 强电磁干扰(EMI)耦合进信号线致读数跳变; 极端温度超出元器件工作范围, 造成性能异常或永久损坏。这些机理相互交织, 需系统分析以支撑精准健康管理。

2 自动化仪表的多层次故障诊断技术

2.1 基于模型的诊断方法

基于模型的诊断(Model-Based Diagnosis, MBD)是利用对仪表工作机理的深刻理解, 建立其数学或物理模型, 通过比较模型的预期输出与仪表的实际输出来检测和隔离故障。对于过程模型法, 可以将仪表视为整个工艺过程的一个环节, 利用已知的物料平衡、能量平衡等过程方程, 推算出某个参数的理论值, 再与该参数仪表的实测值进行比较, 偏差过大即可判断仪表可能故障。

这种方法适用于存在强相关性的多变量系统。对于解析冗余法,则是针对仪表自身建立一个高保真的解析模型。例如,对于科里奥利质量流量计,可以建立其振动管动力学模型,模型的输入是驱动信号,输出是传感器信号。通过观测器(如卡尔曼滤波器)估计传感器信号,并与实际测量值对比,残差信号即可用于故障检测。MBD方法的优点是物理意义明确,诊断结果可信度高,但其缺点是对模型的准确性依赖性强,且建模过程复杂,尤其对于机理复杂的智能仪表,建立精确模型十分困难。

2.2 基于信号处理的诊断方法

当仪表的内部机理难以精确建模时,基于信号处理的方法提供了一条有效的替代路径。这类方法的核心思想是从仪表的原始输出信号(如4-20mA电流、HART数字信号、现场总线报文)中提取能够表征其健康状态的特征量。时域分析是最基础的方法,通过计算信号的均值、方差、峰峰值、峭度等统计量,可以有效识别信号的漂移、噪声增大或突变。频域分析(如傅里叶变换、功率谱密度分析)则擅长于发现信号中隐藏的周期性故障特征,例如,轴承磨损通常会在特定频率处产生特征谐波^[2]。时频域分析(如小波变换、希尔伯特-黄变换)结合了时域和频域的优点,特别适合于分析非平稳、瞬态的故障信号,能够精确定位故障发生的时刻。此外,信息熵、分形维数等非线性动力学特征量,也被用于刻画信号的复杂度和规律性变化,对早期微弱故障的检测具有独特优势。

2.3 基于知识与数据驱动的诊断方法

随着智能仪表的普及,它们不仅能输出主测量值,还能通过HART或现场总线上传大量的自诊断信息和过程参数(如温度、压力、设备状态码、报警代码等)。这为基于知识和数据驱动的诊断方法提供了丰富的数据源。专家系统将领域专家的经验 and 规则编码成知识库,通过推理机对仪表的多维状态信息进行逻辑判断,从而得出故障结论。例如,“如果阻尼时间常数异常增大,且过程噪声水平高,则可能是引压管堵塞”。机器学习方法,特别是监督学习算法(如支持向量机SVM、随机森林、神经网络),可以通过学习大量历史故障样本数据,自动构建从输入特征(多维状态参数)到输出标签(故障类型)的映射关系。这种方法不依赖于精确的物理模型,适应性强,但其性能高度依赖于训练数据的质量和数量。近年来,深度学习(如卷积神经网络CNN、长短期记忆网络LSTM)因其强大的特征自动提取和序列建模能力,在处理高维、时序性的仪表数据方面展现出巨大潜力。

3 预测性维护(PdM)的核心技术体系

3.1 数据采集与融合

预测性维护的基石是全面、高质量的数据。这要求构建一个覆盖仪表全生命周期的多源数据采集体系。数据来源包括:实时过程数据(来自DCS/SCADA的主测量值、设定值、输出值);仪表自诊断数据(通过HART/DD或现场总线获取的设备健康状态、内部温度、电子部件状态、过程条件诊断等);离线校准数据(历次校准报告中的误差、修正值);以及环境与工况数据(如环境温度、湿度、管道振动、介质成分)。由于这些数据来源各异、格式不同、采样频率不一,必须采用数据融合技术(如卡尔曼滤波、D-S证据理论)对其进行时空对齐、去噪和互补,形成一个统一、一致的健康状态数据视图。

3.2 健康指标(HI)的构建

健康指标(Health Indicator, HI)是量化表征设备当前健康状态的单一或复合数值,其值域通常从1(全新健康)单调递减至0(完全失效)。构建一个敏感、鲁棒的HI是PdM成功的关键。对于有明确失效阈值的仪表,可以直接使用其关键性能参数(如零点漂移量、量程漂移量)作为HI^[3]。更通用的方法是通过降维技术(如主成分分析PCA、线性判别分析LDA)或特征加权融合,将多个相关的状态特征量综合成一个HI。HI的设计必须确保其能够清晰地反映设备从健康到失效的整个退化过程,并对早期微弱的性能劣化足够敏感。

3.3 剩余使用寿命(RUL)预测

在获得HI序列后,下一步是预测设备的剩余使用寿命(Remaining Useful Life, RUL),即从当前时刻到其性能退化至失效阈值所需的时间。RUL预测模型主要分为三类:基于物理模型的方法,通过建立描述性能退化过程的微分方程(如Wiener过程、Gamma过程)来进行外推预测,但其对先验知识要求高。基于数据驱动的方法是当前的主流,其中回归模型(如支持向量回归SVR、高斯过程回归GPR)可以直接学习HI与时间的关系;递归神经网络(如LSTM、GRU)则擅长捕捉HI序列中的长期依赖关系,能更准确地预测未来的退化轨迹。混合模型结合了物理模型的先验知识和数据驱动模型的学习能力,通常能取得更好的预测精度和泛化能力。

3.4 维护决策优化

预测出RUL只是PdM的第一步,最终目标是做出最优的维护决策。这需要将RUL预测结果与企业的生产计划、备件库存、维修资源、安全风险和经济成本等因素相结合。通常采用成本-效益分析或风险评估模型来确定最佳的维护时机。例如,当预测的RUL小于某个安全裕度,或者继续运行的预期故障风险成本超过预防性维护

成本时,就触发维护工单^[4]。通过将PdM系统与企业的EAM(企业资产管理系统)或CMMS(计算机化维护管理系统)集成,可以实现维护任务的自动生成、派发和跟踪,形成一个闭环的智能运维管理体系。

4 未来展望:智能仪表运维的新范式

4.1 数字孪生赋能深度洞察

通过在虚拟空间中构建一个与物理仪表完全同步、高保真的数字镜像,可以实现对仪表全生命周期状态的实时映射和深度仿真。这个数字孪生体不仅集成了仪表的几何、物理、行为和规则模型,还持续接收来自物理实体的实时数据流。运维人员可以在数字孪生体上进行“假设分析”(What-if Analysis),模拟不同工况或维护策略对仪表寿命的影响;也可以利用其内置的仿真模型,对物理世界中难以复现的故障进行复盘和根因分析,从而不断优化诊断与预测算法。

4.2 边缘智能实现快速响应

将AI算法部署到靠近数据源头的边缘设备(如智能I/O模块、网关或仪表本身),即边缘计算,是提升PdM系统实时性和可靠性的关键。边缘智能可以在本地完成数据预处理、特征提取和初步的故障诊断,只将关键的告警信息或摘要数据上传至云端,大大减轻了网络带宽压力,并避免了因网络延迟或中断导致的诊断滞后。对于需要毫秒级响应的安全关键型仪表(如SIS系统中的传感器),边缘智能更是不可或缺,它能确保在最短时间内做出本地化决策,保障生产安全。

4.3 人工智能驱动自主进化

未来,PdM系统将不再是静态的工具,而是具备自我学习和进化能力的智能体。通过持续不断地从新的运行数据和维护反馈中学习,基于深度强化学习等先进AI技术的PdM系统能够自主优化其健康指标构建策略、RUL预测模型和维护决策逻辑。它能够识别出新的、未知的

故障模式,并自动更新其知识库。这种自主进化的能力,将使得PdM系统能够适应日益复杂的化工生产环境和不断迭代的仪表技术,真正实现从“被动响应”到“主动预测”再到“自主优化”的终极跨越,为化工生产的本质安全和卓越运营构筑一道坚不可摧的智能防线。

5 结语

化工自动化仪表的可靠性是保障装置安全、稳定、高效运行的基石。本文系统梳理了从故障诊断到预测性维护(PdM)的技术链条:通过剖析典型故障模式与机理,奠定诊断理论基础;构建融合机理、信号、知识与数据的多层次诊断方法,提升复杂故障应对能力;并围绕数据融合、健康指标(HI)、剩余使用寿命(RUL)预测与维护决策优化,阐明PdM实施路径。未来,数字孪生、边缘计算与人工智能的深度融合,将推动形成更智能、自主的下一代运维范式。化工企业应积极投入数据基础设施建设、专业人才培养与智能算法应用,构建覆盖全厂、贯穿仪表全生命周期的健康管理体系,将仪表从潜在风险源转变为生产卓越的可靠伙伴,为行业高质量、可持续发展提供坚实支撑。

参考文献

- [1]黄会中.化工自动化仪表故障诊断方法与维护方式改进[J].中国石油和化工标准与质量,2026,46(04):37-39.
- [2]张泽炜.浅议化工自动化仪表日常维护及常见故障[J].工程与试验,2024,64(01):124-125.
- [3]水生洲.化工自动化仪表常见故障及日常维护[J].化工管理,2022,(05):104-106.
- [4]李东旭,张勇,蒋薇.化工自动化系统里仪器仪表的故障预测方法[C]//中国电力设备管理协会.全国绿色数智电力设备技术创新成果展示会论文集(六).恒力石化(大连)炼化有限公司,2024:340-342.