

自动化仪表故障诊断系统在天然气站场的开发与实践

霍海晓 李永朋 易同旭

国家管网集团北京管道有限公司河北输油气分公司 河北 廊坊 065700

摘要: 我国能源结构优化调整与“双碳”目标推进,使天然气在国家能源体系中的地位愈发重要。天然气站场作为连接上下游的关键枢纽,其安全稳定高效运行十分关键。自动化仪表是站场智能化监控的核心感知单元,其健康状况影响整个生产系统可靠性。但传统人工巡检和被动响应的维护模式,难以满足现代大型复杂站场对高可用性和预测性维护的需求。本文聚焦自动化仪表故障诊断系统在天然气站场的应用,剖析了站场仪表运维面临的挑战,阐述了一套集数据采集、特征提取、智能诊断与决策支持于一体的故障诊断系统架构。该系统融合专家系统、机器学习模型(孤立森林算法)及数字孪生技术,实现闭环管理,期望为天然气行业智能化运维提供可复制推广的范例。

关键词: 自动化仪表;故障诊断;天然气站场;智能运维;机器学习;数字孪生

引言

全球能源转型下,天然气凭借高效、低污染优势,成为我国现代能源体系的重要支柱。随着天然气消费量攀升,长输管道等基础设施规模扩大、系统复杂度提高。站场普遍采用高度自动化控制系统,各类自动化仪表如同神经系统“感官”,实时感知运行状态。关键仪表故障轻则影响输送效率,重则引发安全事故,造成巨大损失。传统仪表维护采用定期检修(TBM)和事后维修(RTF)模式,TBM有“过度”或“不足”维护风险且成本高,RTF则完全被动,无法满足现代工业对本质安全和连续生产的要求。因此,开发先进的自动化仪表故障诊断系统,实现从“被动响应”到“主动预防”和“预测性维护”转变意义重大,既能提升站场本质安全,又能降低运维成本,保障国家能源供应。

1 天然气站场自动化仪表运维挑战分析

天然气站场自动化仪表运维挑战重重:大型站场仪表种类繁多,不同类别及型号工作原理、失效机理各异,构建统一诊断模型困难;严格安全规程下,真实确认的仪表故障事件罕见,故障数据稀缺且标注困难,深度学习方法难以直接应用;运行工况动态变化,干扰因素多,易产生“虚警”和“漏报”;工业现场对诊断结果可靠性与可解释性要求极高,“黑箱”模型输出难获信任,无法指导维修;新系统需融入现有IT/OT架构,从老旧DCS系统获取实时数据、推送诊断结果、与EAM或CMMS对接形成闭环等系统集成与工程落地难度大,这些都是亟待解决的关键问题。

2 故障诊断系统总体架构设计

针对上述挑战,我们提出了一种“三层四域”的混合式智能故障诊断系统架构,旨在兼顾诊断的准确性、

鲁棒性、可解释性与工程可行性。

2.1 “三层”功能架构

2.1.1 数据感知层

作为系统的“感官”,负责从站场OT层(如Honeywell Experion PKS, Yokogawa Centum VP等DCS/SCADA系统)实时采集仪表的过程变量(PV)、输出(OUT)、设备状态及诊断信息(如HART协议中的设备健康状态)。同时,从IT层的EAM、ERP等系统同步获取静态数据,如仪表位号、型号、量程、安装位置、历史维修记录、校验周期等^[1]。本层采用OPC UA等标准协议确保数据接入的安全与兼容性。

2.1.2 智能分析层

这是系统的核心“大脑”。它包含三个相互协同的诊断引擎:

基于规则的专家系统(Rule-Based Expert System, RBES):将领域专家长期积累的故障处理经验固化为一组“IF-THEN”规则。例如,“IF 压力变送器PV值长时间(>30分钟)保持恒定不变 AND 工艺上确认该点压力应有波动 THEN 报警:疑似引压管堵塞或传感器卡滞”。该引擎响应快、逻辑清晰、可解释性强,能有效处理那些机理明确、症状典型的故障。

数据驱动的非监督/半监督学习模型:针对RBES难以覆盖的、复杂的、未知的故障模式,引入机器学习模型。考虑到故障数据稀缺,我们主要采用无监督异常检测算法。经过对比实验,孤立森林(Isolation Forest, iForest)算法因其对高维数据、非线性关系的良好适应性,以及对异常值敏感、计算效率高的特点,被选为主要算法。iForest通过随机选择特征和分割值来“孤立”数据点,异常点因其稀有性,通常会被更快地孤立,从而获得更高

的异常分数。此外，我们还利用少量已知故障样本，采用半监督学习策略（如One-Class SVM）对模型进行微调，以提升特定故障类型的识别精度。

数字孪生辅助分析模块：构建关键设备（如压缩机、分离器）及其关联仪表的轻量化数字孪生体。当诊断引擎发出警报时，该模块可以基于实时数据驱动孪生体进行仿真，复现故障场景，帮助区分是仪表自身故障还是由上游工艺异常（如两相流、水合物形成）引起的测量偏差，从而大幅降低误报率。

2.1.3 应用服务层

负责将智能分析层的成果转化为用户价值。主要功能包括：（1）可视化告警中心：以GIS地图、P&ID图等形式直观展示故障仪表的位置、类型、置信度等级和初步诊断结论。（2）根因分析（RCA）报告：自动生成包含故障特征、可能原因、关联证据链（如相关联仪表的趋势对比）的详细报告，供工程师深度研判。（3）维修决策支持：根据故障的紧急程度、备件库存情况、人员排班等因素，智能推荐最优的维修策略（立即处理、计划内处理、继续观察）并自动生成EAM工单^[2]。（4）知识库自学习：将工程师对诊断结果的反馈（确认或修正）以及最终的维修记录，反哺到专家系统规则库和机器学习模型中，实现系统的持续进化。

2.2 “四域”技术融合

为确保系统稳健可靠，我们在技术选型上强调四个领域的深度融合：（1）OT域：深度理解仪表通信协议（HART, FF, Profibus PA）和DCS系统架构，确保数据采集的实时性与完整性。（2）IT域：采用微服务架构、容器化（Docker/K8s）部署，保证系统的高可用性和可扩展性；利用消息队列（如Kafka）实现数据的削峰填谷与解耦。（3）DT域（数据技术）：构建统一的数据湖，对多源异构数据进行清洗、对齐、特征工程，为上层分析提供高质量数据基底。（4）AT域（分析技术）：融合符号主义（专家系统）与连接主义（机器学习）的优势，形成混合智能。

3 关键技术实现

3.1 数据预处理与特征工程

原始数据质量直接决定诊断效果。需要实施以下关键步骤：（1）数据清洗：剔除明显的坏值（如超出量程的数值）、处理通信中断造成的缺失值（采用线性插值或基于关联仪表的协同过滤填充）。（2）工况划分：利用聚类算法（如K-means）或基于规则的方法，将连续的运行数据划分为若干个相对稳定的“稳态工况窗口”。在每个窗口内分别建立诊断模型，有效规避了工况切换带

来的干扰。（3）特征构造：除了原始PV值，我们还构造了丰富的衍生特征，如：统计特征：滑动窗口内的均值、方差、偏度、峰度。时域特征：变化率、累计变化量。频域特征：（对高频采样数据）通过FFT提取主导频率成分。关联特征：与上下游或物理上强相关的仪表读数的比值、差值。例如，孔板流量计的差压与静压之比。

3.2 孤立森林算法在仪表异常检测中的应用

孤立森林的核心思想是：异常点是“少数且不同”的，因此它们在随机构建的二叉树中路径更短。具体到仪表诊断：（1）输入：对于待监测的N台仪表，在一个稳态工况窗口内，每台仪表提取M个特征，构成一个 $N \times M$ 的特征矩阵^[3]。（2）模型训练：使用大量历史正常运行数据训练iForest模型。模型学习的是正常数据的分布模式。（3）异常评分：对于新的实时数据窗口，计算每台仪表对应的异常分数（Anomaly Score）。分数越接近1，表示越异常；越接近0.5，表示越正常。（4）阈值设定：通过分析历史数据中已知故障点的分数分布，结合业务对误报/漏报的容忍度，动态设定报警阈值。相较于传统的阈值报警，iForest能够捕捉到那些未超出量程但偏离了正常行为模式的“软故障”，这是其最大优势。

3.3 诊断结果融合与决策

单一诊断引擎可能存在局限。我们设计了一个加权投票机制来融合RBES和iForest的结果：如果RBES和iForest同时对同一仪表发出高置信度报警，则系统直接确认故障，并触发最高级别告警。如果仅有一个引擎报警，则系统将其标记为“疑似故障”，并启动数字孪生模块进行辅助验证。若孪生仿真结果支持故障判断，则升级为确认故障；否则，降级为低优先级提示，供人工复核。所有诊断结果都会附带可解释性信息。例如，iForest会指出是哪些特征（如“变化率方差过大”）导致了高异常分数。

4 系统实践场景与应用

4.1 典型站场环境与部署前提

自动化仪表故障诊断系统的工程化落地，需依托于具备一定信息化和自动化基础的天然气站场环境。典型的实践对象通常为大型压气站、分输站或LNG接收站等关键节点设施。这类站场普遍具有以下特征：工艺流程复杂、设备密集、自动化控制系统（如DCS/SCADA）成熟、部署有大量智能仪表（支持HART、FF等协议），并已建立初步的企业资产管理系统（EAM/CMMS）。这些条件构成了系统实施的必要前提，确保了数据可获取、模型可训练、结果可闭环。在部署前，需完成对站场IT/OT架构的全面评估，明确数据源接口、网络拓扑、安全

策略及现有业务流程，为后续的系统集成奠定基础。

4.2 核心实践场景

系统的实践过程可归纳为三大核心场景，覆盖从数据接入到业务价值实现的完整链条。

4.2.1 多源异构数据融合与治理场景

该场景是系统运行的基石。实践中，需打通OT层与IT层的数据壁垒。一方面，通过标准工业通信协议（如OPC UA）从DCS/SCADA系统实时采集仪表的过程变量、设备状态及诊断信息；另一方面，通过API或数据库对接方式，从EAM、ERP等系统同步获取仪表台账、历史维修记录、校验周期、备件库存等静态与事件型数据。在此基础上，构建统一的数据湖或数据中台，实施数据清洗、对齐、去噪、工况划分等预处理操作，形成高质量、结构化的分析数据集^[4]。此场景的关键在于建立可持续的数据质量监控与治理体系，确保输入数据的可靠性与时效性。

4.2.2 混合智能模型部署与在线推理场景

该场景聚焦于诊断能力的工程实现。在离线阶段，利用历史运行数据（以正常数据为主）训练无监督或半监督机器学习模型（如孤立森林），并由领域专家协同构建初始的专家规则库。在在线阶段，将训练好的模型和规则引擎部署于站场边缘计算节点或私有云平台。系统以流式或准实时方式接收新数据，通过特征工程提取关键指标，分别送入专家系统和机器学习模型进行并行诊断。诊断结果经融合决策后，生成包含故障类型、置信度、风险等级及初步原因的结构化告警信息。此场景强调模型的轻量化、低延迟与高可用性，以满足工业现场的严苛要求。

4.2.3 人机协同与业务闭环集成场景

该场景旨在将技术能力转化为实际业务价值。系统通过多终端可视化界面（如中控室大屏、工程师工作站、移动APP）向不同角色用户推送差异化信息：操作员关注全局健康态势与高风险告警，工程师侧重根因分析与处

置建议，维护人员则接收具体的维修工单指引。最关键的是，系统需与站场现有的EAM/CMMS深度集成。当确认故障后，能自动生成包含故障详情、建议措施、所需资源等信息的标准化维修工单，并推送至EAM系统，触发后续的派工、执行、验收、反馈等标准运维流程。同时，工程师对诊断结果的确认或修正，以及最终的维修结论，会作为反馈数据回流至系统，用于知识库更新和模型迭代优化，形成“监测-诊断-决策-执行-学习”的完整闭环。

5 结语

本文围绕自动化仪表故障诊断系统在天然气站场的应用，详细介绍了其开发思路、技术架构、核心算法及工程实践。该系统融合专家系统、孤立森林等机器学习算法与数字孪生技术，构建了智能诊断平台，有效应对了站场复杂运维挑战。展望未来，系统优化空间广阔，可深化AI应用，探索图神经网络与强化学习；拓展诊断范围至整个控制回路和工艺单元；构建云边协同架构，适应大规模管网集中监控；融入更大生态，与管道完整性管理等系统联动，支撑天然气产业链智能化运营。该系统的成功实践，标志着天然气站场运维模式迈向智能化新阶段，既是技术革新也是管理升级，对保障国家能源安全、推动行业高质量发展意义深远。

参考文献

- [1]任丽颖.自动化仪表在天然气行业中的应用分析[J].中国设备工程,2022,(18):201-203.
- [2]赵妍,王鑫,马克远.仪表自动化技术在天然气管道工程中的应用[J].化工管理,2025,(19):90-93.
- [3]李海.天然气管道工程中的仪表自动化控制技术分析[J].集成电路应用,2023,40(11):60-61.
- [4]王晨煜,范劲松,程伟,等.基于故障树的天然气流量计仪表故障自动化识别研究[J].自动化与仪表,2023,38(12):74-78+90.