

基于人工智能的工业仪表自动化系统设计与实现

文/敬芃辉
国家管网集团天津液化天然气有限责任公司

为解决传统工业仪表自动化系统在智能化程度方面的不足，设计一种基于人工智能的工业仪表自动化系统。该系统利用多源异构传感器阵列采集工业数据，并采用融合深度学习算法的模型进行数据分析、预测性维护和故障诊断。通过在高保真仿真环境中进行实验验证，结果表明，相比于传统的控制策略，该系统在控制准确度、能耗优化以及故障诊断效率方面均有显著提升，能够有效提高工业生产效率和安全性。

近年来，人工智能技术的飞速发展给工业仪表自动化带来了新的机遇与挑战。将人工智能算法与工业仪表自动化系统相结合，可以实现数据的智能采集与分析、自主决策与优化控制等功能，从而大幅提升系统的智能化水平。本文将探讨人工智能赋能工业仪表自动化的可行性与优势，并提出一种基于人工智能的工业仪表自动化系统设计方案，旨在为相关领域的研究与应用提供参考。

人工智能赋能工业仪表自动化的可行性与优势

人工智能在工业仪表自动化领域的应用前景广阔，它能够从大量工业数据中自主学习和提取关键信息，进而实现工业过程的智能化优化与控制。以预测性维护为例，实时收集和分析振动、温度、压力等关键参数，结合支持矢量机（SVM）或卷积神经网络（CNN）等机器学习算法，可准确预测设备剩余寿命和潜在故障，为设备健康管理提供有力支持。在复杂工业过程控制中，传统PID控制器在 high 准确度、强非线性系统控制方面存在不足。而人工智能优化算法，如遗传算法（GA）、粒子群优化（PSO）等，能够优化PID控制器参数（如 K_p 、 K_i 、 K_d ），实现精确控制，并根据工况变化自适应调整

控制策略。此外，人工智能还可用于工业仪表的智能标定与自诊断。通过分析仪表的输入输出数据，建立智能标定模型，实现仪表自动校准，降低人工操作误差。同时，基于智能算法的自诊断功能能及时发现仪表异常状态，确保测量数据的可靠性。

基于人工智能的工业仪表自动化系统设计

1. 数据采集与分析

基于人工智能的工业仪表自动化系统的数据采集与分析模块采用了多源异构传感器阵列，包括振动传感器、温度传感器和压力传感器等，实现了对工业过程的全面监测。采集的数据经过自适应小波阈值去噪、经验模态分解等预处理技术，有效消除了环境噪声与测量误差的影响。为进一步提取数据的本质特征，系统采用了基于Isomap算法的非线性降维方法，将原始高维数据（如1024维）映射到低维流形空间（如32维），保留了数据的内在结构信息。在特征空间中，系统构建了一个融合卷积神经网络（CNN）和长短期记忆网络（LSTM）的深度学习模型，用于设备的健康状态评估与预测。CNN模型可提取数据的局部特征，而LSTM模型能够捕捉时序数据的长期依赖关系。模型的计算式为

$$\hat{y} = \text{Softmax}(W_o \cdot (\text{LSTM}(h_t) \oplus \text{CNN}(x_t)) + b_o) \quad (1)$$

式中, $\hat{y}$ 为预测的设备健康状态概率分布; x_t 为 t 时刻输入特征; h_t 为LSTM的隐藏状态; W_o 和 b_o 分别为全连接层的权重矩阵和偏置项; $\oplus$ 为特征拼接操作。

通过对该模型的训练, 系统可以根据采集的实时数据, 动态评估设备的健康状态, 并及时预警潜在的异常情况, 确保工业生产的安全与稳定。

2. 自动控制与决策

基于人工智能的工业仪表自动化系统的自动控制与决策模块以强化学习为核心, 实现了对复杂工业过程的智能调控。系统采用了深度确定性策略梯度(DDPG)算法, 将连续的状态空间映射到连续的动作空间, 生成最优控制策略。状态空间包括设备的实时工况参数, 如温度、压力、流量等, 维度可达上千。动作空间则包括各执行器的连续控制量, 如阀门开度、电机转速等。DDPG算法由一个策略网络和一个值函数网络组成, 策略网络用于生成控制策略, 值函数网络用于评估策略的优劣。策略网络的数学表达式为

$$\mu(s|\theta^\mu) = \tanh(W_2^\mu \cdot \text{ReLU}(W_1^\mu \cdot s + b_1^\mu) + b_2^\mu) \quad (2)$$

式中, $\mu(s|\theta^\mu)$ 为在状态 s 下采取的动作; θ^μ 为策略网络的参数, 包括权重矩阵 W_1^μ, W_2^μ 和偏置项 b_1^μ, b_2^μ 。

通过优化策略网络的参数, 可最大化长期累积奖赏, 实现最优控制。系统还引入模型预测控制(MPC)模块, 用于处理约束条件下的最优控制问题。MPC模块基于系统的动态模型, 预测未来一定时域内的系统行为, 并求解一个带约束的优化问题, 得到最优控制序列。通过DDPG算法与MPC模块的协同工作, 系统可在满足各类约束条件(如安全阈值、执行器限制等)的前提下, 实现工业过程的自动调优与控制, 大幅提高生产效率与产品质量。

3. 预测性维护

预测性维护模块致力于实时监控并预测设备健康状态, 旨在实现故障预警与寿命管理, 从而防止非计划停机, 确保生产系统的连续稳定运行。该模块采用一种融合门控循环单元(GRU)与注意力机制的深度学习模型, 以有效应对工业时序数据的长期依赖与非平稳特性问题。模型输入主要包括两部分: 一是设备运行期间由多模态传感器采集的实时数据, 如振动、温度和压力等, 这些数据直接反映设备当前运行状态; 二是历史维修记录、操作参数

等辅助信息, 它们提供了设备使用历史、运行环境及操作条件的背景知识。

模型运用深度学习算法对这些多源异构数据进行深度融合与特征抽取, 旨在揭示设备退化过程中的内在规律与潜在故障模式。具体而言, GRU结构利用其特有的门控机制捕捉并保留时序数据中的长期依赖关系, 即使在时间序列长度较大或数据分布不均匀的情况下, 也能保持对历史信息的有效记忆。同时, 注意力机制有助于模型聚焦于输入序列中对当前预测任务最具影响力的部分, 从而提升模型在处理非平稳数据时的鲁棒性和预测准确度。模型的核心部分的数学表达式为

$$h_t = \text{GRU}(x_t, h_{t-1}) = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (3)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, x_t]) \quad (4)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]), r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (5)$$

$$\alpha_{it} = \frac{\exp(e_{it})}{\sum_{j=1}^T \exp(e_{jt})}, e_{it} = v^\top \tanh(W_a \cdot [h_t, h_i]) \quad (6)$$

式中, h_t 为 t 时刻隐藏状态; x_t 为 t 时刻输入特征; z_t 和 r_t 分别为更新门和重置门; W_h, W_z, W_r 为对应的权重矩阵; α_{it} 为 t 时刻对 i 时刻的注意力权重; e_{it} 为对应的注意力得分; v 和 W_a 为注意力机制的参数。

通过注意力机制, 模型可自适应关注时序数据中的关键时刻, 提高预测的准确性。基于该模型, 系统可动态预测设备的剩余寿命(RUL), 并根据预测结果优化维护策略, 最小化维护成本与生产损失。

4. 故障诊断与优化

基于人工智能的工业仪表自动化系统的故障诊断与优化模块采用了一种融合卷积神经网络(CNN)和变分自编码器(VAE)的深度学习框架, 实现了对复杂工业系统的故障检测、隔离与根因分析。该框架首先利用CNN对高维传感器数据进行特征提取, 然后将提取的特征输入VAE进行无监督学习, 构建正常工况下的数据分布。在此基础上, 通过引入基于Wasserstein距离的异常度量, 可以敏感地检测出系统的异常状态, 并基于异常特征的差异性进行故障隔离。异常度量的计算式为

$$D_W(p_n \| p_a) = \inf_{\gamma \in \Pi(p_n, p_a)} \mathbb{E}_{(x,y) \sim \gamma} [\|x - y\|] \quad (7)$$

式中, p_n 和 p_a 分别为正常数据和异常数据的分布; $\Pi(p_n, p_a)$ 为两个分布之间的联合分布集合; E 为期望操作符。

通过最小化正常数据和异常数据之间的 Wasserstein 距离，可以得到一个鲁棒的异常检测器。在故障隔离的基础上，系统还集成了基于 Granger 因果分析和图神经网络（GNN）的根因诊断算法，可以自动推理故障的传播路径与原因。其中，Granger 因果分析用于刻画异常变量之间的因果关系，而 GNN 则用于建模系统的拓扑结构与物理规律，实现全局范围内的根因定位。通过故障诊断与优化模块，系统可以及时发现并定位工业过程中的异常情况，提供可解释的诊断结果，并根据诊断结果自动生成优化的控制策略，最小化故障对生产的影响，提高系统的安全性与可靠性。

系统实现与仿真验证

1. 仿真环境搭建与实验设计

为验证基于人工智能的工业仪表自动化系统的有效性，搭建一个高保真的仿真环境，并设计一系列实验。仿真环境基于工业标准的 OPC UA 通信协议，集成了多个虚拟的现场设备，如 PLC、DCS、智能传感器等，可以真实地模拟工业过程的动态特性。同时，环境还提供了一组接口，用于连接不同的人工智能算法模块，如数据分析、预测控制和故障诊断等。为全面评估系统的性能，实验设计覆盖了多个典型的工业场景，如炼油、化工、电力等，并考虑了不同的工况条件，如正常、异常、瞬态等。在每个场景下，通过调整工艺参数（如温度、压力、流量等）和故障参数（如故障类型、严重程度、发生时间等），生成了大量的仿真数据，用于训练和测试人工智能模型。此外，还设计了一系列对比实验，包括与传统的基于规则的自动化系统、单一的机器学习模型等进行性能对比，以突出人工智能带来的性能提升。

2. 实验结果与讨论

通过在高保真仿真环境中进行大量实验，全面评估了基于人工智能的工业仪表自动化系统的性能。实验结果表明，该系统在多个典型工业场景下均表现出色，显著优于传统的自动化方法。以炼油场景为例，系统在控制准确度、能耗优化、故障诊断等方面取得了突出成果。表1展示了不同控制策略下的关键性能指标对比。可以看出，基于强化学习的智能控制算法将温度波动幅度降低了68.3%，

同时将能耗降低了23.6%，远超PID控制与模糊控制的效果。此外，系统还通过预测性维护实现了设备的健康管理。基于注意力机制的GRU模型在压缩机的剩余寿命预测任务上取得了较高的准确性，平均误差仅为6.2%，且能够提前3—5天预警潜在的故障风险，为维护决策提供了可靠依据，见表2。在故障诊断方面，系统采用了融合CNN和VAE的异常检测算法，结合Granger因果分析与图神经网络实现了精准的根因定位。实验中，系统成功诊断出了热交换器结垢、泵气蚀等多类复杂工业故障，平均定位时间小于1 min，大幅提升了诊断效率。总体而言，实验结果充分证明人工智能技术在工业仪表自动化领域的优越性，为实现智能制造提供新的解决方案。未来，还需进一步拓展算法的适用场景，提高系统的鲁棒性与可解释性，并加快工程化应用进程，推动人工智能在工业领域的深度融合。

表1 不同控制策略的性能对比

控制策略	温度波动幅度/℃	能耗/ (kJ/kg)
PID控制	24.6	1 423.5
模糊控制	16.2	1 285.7
智能控制	7.8	1 087.3

表2 压缩机剩余寿命预测性能对比

预测模型	平均误差 (%)	提前预警时间/天
LSTM	9.4	2-4
GRU	7.8	2-5
注意力GRU	6.2	3-5

结束语

本文探讨了人工智能技术在工业仪表自动化领域的应用，提出一种基于人工智能的工业仪表自动化系统设计方案。该方案综合利用机器学习、深度学习、强化学习等前沿算法，实现了工业数据的智能采集与分析、自适应控制与优化决策、设备的预测性维护与故障诊断等功能，显著提升工业自动化系统的智能化水平。通过在高保真仿真环境中的实验验证，证明该方案在多个典型工业场景下的有效性与优越性，为实现智能制造提供了新的思路与方法。未来，还需进一步加强人工智能在工业领域的理论研究与应用实践，促进制造业的转型升级。EA

（收稿日期：2024-06-12）