

DOI: 10.13382/j.jemi.B2508558

数字孪生驱动的离心压缩机故障诊断方法^{*}

陈泰峰¹ 程 雨² 连远锋²

(1. 国家能源集团泰州发电有限公司 泰州 225300; 2. 中国石油大学(北京)人工智能学院 北京 102249)

摘 要:离心式压缩机作为油气站场中的关键设备,其运行状态直接影响生产系统的稳定性与安全性。针对压缩机故障诊断模型由于工况复杂、故障数据不足等现象导致泛化能力弱、物理解释性差等问题,设计了一种数字孪生驱动的离心压缩机故障诊断方法。首先,建立离心压缩机“数据采集-映射-融合与优化-驱动”数字孪生框架,实现运行信息在数字孪生体中的存储与融合。其次,通过变分模态分解(variational mode decomposition,VMD)将时序信号分解为具有有限带宽的本征模态分量,将压缩机状态特征空间与热力学状态变量进行映射。最后,提出基于物理信息的可扩展长短期记忆网络(physics-informed extended long short-term memory network,PX-LSTM)故障诊断模型,将离心压缩机运行过程中的关键物理特征嵌入至可扩展长短期记忆网络(extended long short-term memory network,xLSTM)结构中进行联合建模,引导模型在学习历史故障特征的同时,遵循系统的内在热力学行为。实验结果表明,所提出的模型在多工况、多故障类型识别任务中均优于其他主流方法,验证其在油气数字孪生系统中应用的可行性与有效性。

关键词:数字孪生;压缩机;故障诊断;长短期记忆网络

中图分类号: TP277;TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.25

Digital twin-driven fault diagnosis method for centrifugal compressors

Chen Taifeng¹ Cheng Yu² Lian Yuanfeng²

(1. CHN Energy Taizhou Power Generation Co., Ltd., Taizhou 225300, China;
2. College of Artificial Intelligence, China University of Petroleum, Beijing 102249, China)

Abstract: As a critical piece of equipment in oil and gas stations, the operating condition of centrifugal compressors directly affects the stability and safety of the production system. To address the issues of poor generalization and limited physical interpretability in compressor fault diagnosis models—caused by complex operating conditions and insufficient fault data—this paper proposes a digital twin-driven fault diagnosis method for centrifugal compressors. First, a digital twin framework for centrifugal compressors is constructed, comprising the stages of data acquisition, mapping, fusion and optimization, and model-driven analysis, enabling the storage and integration of operational information within the digital twin entity. Second, variational mode decomposition (VMD) is employed to decompose time-series signals into intrinsic mode functions with limited bandwidth, thereby mapping compressor status features to thermodynamic state variables. Finally, a physics-informed extended long short-term memory network (PX-LSTM) fault diagnosis model is developed, which embeds key physical features from the compressor's operational process into the extended long short-term memory network (xLSTM) structure for joint modeling. This design guides the model to learn historical fault features while adhering to the underlying thermodynamic behavior of the system. Experimental results demonstrate that the proposed model outperforms mainstream approaches across multiple operating conditions and fault types, validating its feasibility and effectiveness in oil and gas digital twin systems.

Keywords: digital twin; compressor; fault diagnosis; long short-term memory network

0 引言

离心压缩机作为现代工业体系中的核心动力装备,是石油化工、天然气输送、煤化工及能源等领域不可或缺的关键设备。压缩机故障诊断技术作为设备运维的关键技术,不仅关系到压缩机的运行性能,还直接影响系统的安全性,具有重要的研究价值和广阔的实际应用前景。

离心压缩机故障诊断方法主要分为两类:传统方法和深度学习方法。传统故障诊断基于信号分析方法,通过提取时频域特征进行故障分类^[1-2]。传统故障诊断方法受限于其结构与表达能力,难以深入挖掘复杂数据中的潜在特征,制约了其在复杂工况下的故障识别性能^[3]。随着深度学习的发展,将其应用于压缩机故障诊断受到学者们的广泛关注。Dixit等^[4]提出一种条件生成对抗网络(conditional generative adversarial network, GAN)模型,结合元学习实现往复压缩机状态预测。Gribbestad等^[5]提出基于卷积神经网络(convolutional neural network, CNN)的异常检测方法,对空气压缩机进行健康状态监测。Tian等^[6]提出基于多分段注意力的长短期记忆网络(multi-segment attention-based long short-term memory network, MA-LSTMs)用于恶劣环境下的海上石油平台的往复压缩机异常诊断。Yuan等^[7]将故障树映射动态贝叶斯网络(dynamic Bayesian network, DBN)方法应用于离心式压缩机组的可靠性研究,并对其可用性和可靠性进行了动态评价。Pu等^[8]在长短期记忆网络(long short-term memory network, LSTM)模型中嵌入自注意力模块,通过增强关键数据特征敏感性来实现工业压缩机状态预测。尽管上述方法取得较好的效果,但面对复杂的工况,深度学习模型缺乏对物理规律的建模与解释能力,无法进一步提高故障识别的准确性和可解释性。

近年来,数字孪生(digital twin)技术在工业领域得到了广泛的应用,被视为促进制造业智能化和数字经济发展的关键力量^[9]。该技术以数字化方式生成物理实体的实时动态虚拟映像,依赖实时数据流驱动模型,模拟其真实世界的行为与状态。利用虚实交互、数据传输和智能感知能力,该技术可精确、实时且高效地监控和服务物理对象。作为物理世界与虚拟世界的连接桥梁,数字孪生促成了产品全生命周期的双向映射,为工业领域设备迈向无人化、自动化及智能化管理带来了突破性的解决方案^[10]。Xu等^[11]使用深度迁移学习将训练的诊断模型从虚拟空间迁移到物理空间,以实现实时监控和预测性维护。Wang等^[12]提出数字孪生参考模型,用于旋转机械不平衡量化和定位故障诊断。Yang等^[13]提出虚实相结合的数字孪生驱动的复合故障诊断方法,用于海底生产

系统的故障排除。Xu等^[14]提出离心泵故障诊断方法,利用由图迁移学习模型提供支持的数字孪生框架来解决恶劣的运行环境下的故障识别。尽管数字孪生能够有效模拟系统行为,并通过与现实环境的交互提升模型的适应性,但数据驱动孪生模型在面对复杂机械系统时存在对数据分布过度依赖,泛化能力不足,难以提供可信的故障依据的问题。

针对上述问题,本文提出一种基于物理过程的扩展长短期记忆网络(physics-informed extended long short-term memory network, PX-LSTM)方法。首先,针对现有模型在复杂工况下泛化能力不足问题,通过变分模态分解(variational mode decomposition, VMD)^[15]将复杂信号分解为具有有限带宽的本征模态分量,将压缩机状态特征空间与热力学状态变量进行映射。其次,针对现有模型物理可解释性不足的问题,将离心压缩机热力学状态方程转化为物理一致性约束,嵌入至可扩展长短期记忆网络(extended long short-term memory network, xLSTM)的损失函数的计算中,实现从单纯的数据拟合向物理感知驱动的转变。最后,结合数字孪生模型,搭建离心压缩机故障诊断系统,实现对压缩机多工况、多状态运行特征的建模和预测性维护。

1 系统模型及问题描述

1.1 系统模型

针对物理压缩机故障诊断中受生产环境限制等因素的影响,提出数字孪生辅助强化学习的离心式压缩机故障诊断系统模型,如图1所示。离心式压缩机数字孪生系统架构如下:1)物理压缩机,作为现实中载体,由传感器和工业现场中的真实设备组成,设备主要包括叶轮、扩压器、蜗壳、电机、齿轮箱等;2)虚拟压缩机,作为根据物理压缩机建立的虚拟模型,是物理压缩机的孪生体,包括数字设备和数字传感器,有效地重现了物理工业现场中的压缩机,通过虚拟压缩机,可以提前发现潜在故障,制订更有效的诊断计划,提高压缩机的整体运营效率和安全性;3)故障诊断算法,基于物理压缩机和虚拟压缩机的多源实时监测数据,结合设备运行状态和历史故障模式,精准识别关键部件的异常征兆。通过模型驱动与数据驱动方法融合,提高故障定位的准确性与响应速度,为运维决策和设备调度提供可靠依据。

1.2 压缩机模型

如图2所示,假定压缩机组由 N 个部件组成,结合工业现场实际诊断流程,在设备运行区域中设置轴承、叶轮、密封装置等关键结构,并考虑空间布局、振动干扰以及温度等工况约束限制。通过数字孪生技术构建压缩机




图 1 整体框架图

Fig. 1 The framework of our proposed method

的虚拟模型,将物理压缩机系统与虚拟模型的数据实时对接,通过虚拟模型的持续优化与更新,可实现设备状态的全方位监控,为异常检测提供动态参考框架^[16]。

1.3 压缩机时序数据表示

在工业生产过程中,可以通过采集振动、压力、温度等关键变量来监测压缩机的运行状态^[17]。

假设在任意时刻 t , 对所有相关变量的测量值进行同步记录,形成完整的数据样本,记作 $\mathbf{x}_t = [x_{t,1}, x_{t,2}, \dots, x_{t,m}]^T$, 其中, $\mathbf{x}_t$ 表示在 t 时刻所记录的数据样本, $\mathbf{x}_{t,i} (1 \leq i \leq m)$ 表示该样本在第 t 时刻所记录的第 i 个变量的观测值, m 表示监测变量的个数。对所监测的变量进行长度为 l 的采集后,可生成二维时间序列矩阵,记作 $\mathbf{X}_l = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbf{R}^{N \times m}$, 其中, N 表示所记录的样本




图 2 离心压缩机系统模型

Fig. 2 Centrifugal compressor system model

数量,表示为:

$$\mathbf{X} = \begin{bmatrix} x_1^T \\ x_2^T \\ \dots \\ x_N^T \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{N1} & x_{N2} & \dots & x_{Nm} \end{bmatrix} = \mathbf{R}^{N \times m} \quad (1)$$

定义 1 时序数据低质性

在实际生产过程中,由于传感器采集到的数据通常因噪声干扰、传感器故障或其他问题导致数据出现变量缺失、样本缺失或受到噪声的随机污染而呈现出低质量特性^[18-19],对于样本数据 X_i ,将超出如下范围的值视为异常值:

$$\mu - 3\sigma < x_i < \mu + 3\sigma \quad (2)$$

式中: μ 和 σ 分别表示均值和标准差。

定义时序数据低质性指标 Q_{low} 用于度量评估数据在缺失、异常、波动和采样混乱等方面的质量问题,即:

$$Q_{low} = \lambda_m \frac{n_m}{N} + \lambda_a \frac{n_a}{N} \quad (3)$$

式中: n_m 表示缺失的数据个数; n_a 表示异常的数据个数。

定义 2 时序数据动态性

受复杂的物理化学反应机制、动态噪声干扰及反馈控制等因素影响,压缩机信号具有时序相关性^[20],通过在一段时间内的连续采集获得的工业过程数据具有显著的时间关联特性,各样本点并非相互独立。在时间序列 $x_{t-d} \sim x_t$ 中,某一时刻的样本都与之前若干个样本 $x_{t-1} \sim x_{t-d}$ 具有相关性即:

$$x_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-d}) + \varepsilon_t \quad (4)$$

基于这一特性,可有效利用工业时序数据对生产过程进行状态监测与异常识别。

定义 3 时序数据非平稳性

受生产环境变化、设备老化与磨损以及多种未知干扰等因素的影响,工业生产过程往往难以长期维持在固定的稳定工作点,而是在不同的工作点进行切换,这种工况切换会导致采集到的时序数据在均值、方差等统计特性上发生显著变化,从而使得数据呈现出非平稳性^[21]。相对而言,宽平稳过程的统计特性在时间上保持恒定,其一阶与二阶矩不随时间变化。宽平稳过程满足如下公式:

$$\begin{aligned} E(x_t) &= \mu \\ \text{Var}(x_t) &= \sigma^2 \\ \text{Cov}(x_t, x_{t+k}) &= \text{Cov}(x_{t+h}, x_{t+h+k}) = \rho \end{aligned} \quad (5)$$

式中: μ 和 σ^2 分别表示均值和方差,均不随时间而发生改变; ρ 表示自协方差,仅与时间差有关。

1.4 热力学约束条件

在离心压缩机故障诊断建模过程中,考虑到设备运行中的热力学规律、物理边界限制及数据驱动模型的稳定性需求,应在模型训练与优化目标中引入多种物理与

时序性约束条件。VMD 可将复杂信号分解为一组具有有限带宽的本征模态分量 (IMFs),每个模态 $u_k(t)$ 聚焦一个频率带内,便于故障识别^[22]。这里将每个模态理解为压缩机状态特征空间在热力学状态变量中的映射。

1) 频率带宽约束是将每个模态聚焦于特定频段,对应物理现象的频率特征。对每个模态中心频率 ω_k 设定上下限。

$$\omega_k \in [\omega_k^{\min}, \omega_k^{\max}] \quad (6)$$

2) 模态能量约束,避免某一模态过度主导,确保模态能量分布合理。

$$\|u_k(t)\|_2^2 \leq E_{\max} \quad (7)$$

3) 模态物理相关性约束,保证解的物理可解释性,要求某模态成分与运行参数(如转速、流量)具有最低相关性。

$$\text{Corr}(u_k(t), R(t)) \geq \rho_{\min} \quad (8)$$

4) 热力平衡一致性约束,保证模态分解后热力参数之间保持能量守恒。

$$\begin{aligned} \epsilon_k(t) &= Q_k(t) - W_k(t) - \frac{dU_k}{dt} \\ |\epsilon_k(t)| &< \varepsilon_{tol} \end{aligned} \quad (9)$$

5) 时变特征约束,适应离心压缩机工况变动,确保模态稳定。对相邻时间段的同一模态变化设置限度,增强模型的时序一致性。

$$\|u_k^{(i)}(t) - u_k^{(i+1)}(t)\|_2 \leq \delta \quad (10)$$

2 基于热力学 PX-LSTM 的故障诊断算法模型

2.1 多约束驱动的工业时序数据处理算法 (MCIDPA)

为了提高离心压缩机故障诊断模型的准确性与物理一致性,这里在数字孪生驱动框架下设计并引入一种 MCIDPA 算法。该算法对数据清洗与标准化处理并融合了压缩机运行过程中的热力学原理、模态能量特性以及时序变化规律,从而构建高质量、物理可解释性强的输入特征,MCIDPA 数据处理算法如下。

输入:原始数据矩阵 $\mathbf{X} \in \mathbf{R}^{N \times M}$,窗口长度 w ,VMD 模态数 k
输出:特征矩阵 $\mathbf{X}$

1. 初始化数据结构:设定 $\mathbf{X} = \{x_{t,i}\}$, $(1 \leq t \leq N, 1 \leq i \leq M)$,对每个变量数据 $x_{t,i}$ 执行:
2. 计算均值 μ_i 、标准差 σ_i
3. 根据式(2)标记异常值
4. 根据式(3)计算低质性指标
5. if $Q_{low} \geq q$ (数据低质)使用滑动窗口平均填补缺失值和异常值得到数据 $\mathbf{X}'$
else $\mathbf{X}' = \mathbf{X}$
6. 构造时序样本窗口 $\mathbf{X}_t = [x_{t-w+1}, \dots, x_t]$ 计算 μ_i, σ_i
7. if μ_i, σ_i 不满足式(5),执行差分变换和标准化得到平稳数据 $\mathbf{X}'_t$

else $X' = X_i$

8. 对每个变量数据 $x'_{t,i}$ 执行 VMD 分解得到模态 $u_k(t)$

9. 对每个模态执行如下约束判断:

10. if 中心频率 ω_k 满足式(6)

11. and 模态能量 E_k 满足式(7)

12. and 相关系数 ρ_k 满足式(8)

13. and 能量 $\epsilon_k(t)$ 满足式(9)

then 保留满足约束的模态 u_k

14. else 跳过该模态 u_k

15. 重构输出特征矩阵

$$\hat{X} = [u_1(t), u_2(t), \dots, u_k(t)]$$

16. 输出 $\hat{X} \in \mathbf{R}^{N \times K}$

2.2 离心压缩机热力学模型

为准确表征离心式压缩机在复杂工况下的热力学行为和能量转换特性,这里基于热力学第一定律和理想气体状态方程,构建离心压缩机的物理建模框架。该模型可用于分析压缩过程中的温度、压力、密度等状态变量变化,同时提取具有物理意义的关键特征,为故障诊断与状态预测提供支持。假设压缩过程为可逆等熵过程,气体为理想气体,忽略摩擦、热损失和流动激波等因素,则压缩机内部的质量守恒方程表示为:

$$\frac{dm}{dt} = \dot{m}_{in} - \dot{m}_{out} \quad (11)$$

式中: m 是压缩机内部的气体质量; $\dot{m}_{in}$ 与 $\dot{m}_{out}$ 是分别表示进气与排气的质量流率。根据热力学第一定律,忽略动能和势能变化,压缩机内部的气体系统能量守恒方程为:

$$\frac{dU}{dt} = \dot{Q} - \dot{W} + \dot{m}_{in} h_{in} - \dot{m}_{out} h_{out} \quad (12)$$

式中: U 为压缩机内部气体的内能; $\dot{Q}$ 为传入控制体的热量流率; $\dot{W}$ 为轴功率; h 为进出气体的比焓。

对于理想气体,有:

$$U = m c_v T, h = c_p T, pV = mRT \quad (13)$$

式中: c_p 为定压比热容; c_v 为定容比热容; T 为气体温度; R 为气体常数。因此,内能 U 可以表示为:

$$U = m c_v T \quad (14)$$

轴功率定义为:

$$\dot{W} = P \frac{dV}{dt} \quad (15)$$

将上述内能表达式代入能量守恒方程并对时间求导,则有:

$$\frac{d(m c_v T)}{dt} = \dot{Q} - P \frac{dV}{dt} + \dot{m}_{in} c_p T_{in} - \dot{m}_{out} c_p T_{out} \quad (16)$$

对左边使用乘积求导法则展开:

$$c_v \left(\frac{dm}{dt} T + m \frac{dT}{dt} \right) = \dot{Q} - P \frac{dV}{dt} + \dot{m}_{in} c_p T_{in} - \dot{m}_{out} c_p T_{out} \quad (17)$$

将能量守恒式代入,并整理得:

$$m c_v \frac{dT}{dt} = \dot{Q} - P \frac{dV}{dt} + \dot{m}_{in} (c_p T_{in} - c_v T) - \dot{m}_{out} (c_p T_{out} - c_v T) \quad (18)$$

上述过程描述了压缩机内部温度与压力的动态演化机制,反映其受体积变化、热量输入、气体进出流量与温度差异等因素共同作用的影响。

1) 压缩功率

压缩功率表示压缩机对气体做功的速率,是系统对外的有效输出,基于出口压力和气体流量进行计算,表示为:

$$\dot{W}(t) = P_{out}(t) \cdot Q_{air}(t) \quad (19)$$

2) 热能项

压缩机内部气体内能的大小表示为热能项,表示为:

$$\dot{U}(t) = \dot{m}(t) \cdot c_v \cdot T_{out}(t) \quad (20)$$

3) 能量残差项

能量残差项用于评估输入功率与理论输出之间的偏差,反映了系统的热力一致性,表示为:

$$e_{thermo}(t) = [P_{motor}(t) + P_{water}(t) + P_{oil}(t)] - \dot{W}(t) - \dot{m}(t) \cdot c_v \cdot T_{out}(t) \quad (21)$$

若该残差出现异常波动,可以表示磨损、泄漏、阀门故障或冷却失效等故障征兆。

2.3 xLSTM

LSTM 是递归神经网络(RNN)的变体,通过引入存储单元和门控机制,使得其能有效的捕捉和处理时序信息特征,同时解决 RNN 的消失梯度问题。如图 3 所示, LSTM 单元模型主要包括遗忘门、输入门和输出门,这些门控机制用于在每个时间步有选择地保留或丢弃信息^[23-24]。

遗忘门决定信息的通过量,其过程可以表示为:

$$f_t = \sigma(w_{l1}[h_{t-1}, x_t] + b_{l1}) \quad (22)$$

式中: σ 是 sigmoid 函数 w_{l1} 和 b_{l1} 分别是权重和偏置; h_{t-1} 是前一个单元的输出; x_t 是当前输入。输入门决定新信息能否被细胞单元记忆,其过程可以表示为:

$$i_t = \sigma(w_{l2}[h_{t-1}, x_t] + b_{l2})$$

$$\tilde{C}_t = \tanh(w_{l3}[h_{t-1}, x_t] + b_{l3}) \quad (23)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t$$

式中: w_{l2} 、 w_{l3} 和 b_{l2} 、 b_{l3} 分别是输入门、记忆单元的权重和偏置; $\tanh$ 为激活函数; f_t 、 i_t 分别为遗忘门和输入门的输出; C_t 是记忆单元的输出; C_{t-1} 为前一个记忆单元的输出; $\tilde{C}_t$ 是激活函数 $\tanh$ 的输出。

LSTM 单元的最终输出 h_t 由输出门的输出 o_t 与记忆单元输出 C_t 决定,其过程可以表示为:

$$o_t = \sigma(w_{l4}[h_{t-1}, x_t] + b_{l4})$$

$$h_t = o_t \tanh(C_t) \quad (24)$$




图 3 PXLSTM 网络结构

Fig. 3 PXLSTM network structure

式中: w_{l4} 、 b_{l4} 分别表示输出门的权重和偏置。

为了使 LSTM 能够修改存储决策, sLSTM 引入指数门来替换遗忘门和输入门的激活函数, 以及规范化和稳定化状态。遗忘门如式(25)、输入门如式(26)所示。

$$f_t = \sigma(w_{l1}[h_{t-1}, x_t] + b_{l1}) \text{ORexp}(w_{l1}[h_{t-1}, x_t] + b_{l1}) \quad (25)$$

$$i_t = \exp(w_{l2}[h_{t-1}, x_t] + b_{l2}) \quad (26)$$

为了实现规范化, 引入一个规范化状态 n_t 。将输入门乘以所有未来遗忘门的乘积相加。

$$n_t = f_t n_{t-1} + i_t \quad (27)$$

而指数激活函数可以产生巨大的值, 从而导致溢出。因此, 通过稳定状态 m_t 来稳定门控。

$$m_t = \max(\log(f_t) + m_{t-1}, \log(i_t)) \quad (28)$$

通过稳定状态的遗忘门和输入门如式(29)和(30)所示。

$$i'_t = \exp(\log(i_t) - m_t) = \exp(\tilde{i}_t - m_t) \quad (29)$$

$$f'_t = \exp(\log(f_t) + m_{t-1} - m_t) \quad (30)$$

在前向传递中采用 i'_t 和 f'_t 分别代替 i_t 和 f_t 不会改变整个网络的输出, 也不会改变损失关于参数的导数。

为了提高存储容量, mLSTM 将 LSTM 存储单元从标量 $c \in \mathbf{R}$ 增加到矩阵 $C \in \mathbf{R}^{d \times d}$ 。检索通过矩阵乘法执行。存储键值对的协方差更新规则如下:

$$C_t = C_{t-1} + v_t k_t^T$$

$$q_t = W_q x_t + b_q$$

$$k_t = \frac{1}{\sqrt{d}} W_k x_t + b_k$$

$$v_t = W_v x_t + b_v \quad (31)$$

在时间 t , 想要存储一对向量, 即键 $k_t \in \mathbf{R}^d$ 和值 $v_t \in \mathbf{R}^d$, 在之后的时间点 $t + \tau$ 时, 应通过查询向量

$q_{t+\tau} \in \mathbf{R}^d$ 检索值 v_t 。

2.4 PX-LSTM 损失函数

将热力学定律作为约束嵌入 xLSTM 网络损失函数中, 均方误差损失函数、热力学信息损失函数和正则化损失函数, 即:

$$L_{TOTAL} = \lambda_{MSE} L_{MSE} + \lambda_{PHY} L_{PHY} + \lambda_{REG} L_{REG} \quad (32)$$

式中: λ_{MSE} 是均方误差的损失加权系数; λ_{PHY} 是物理信息的加权系数; λ_{REG} 是正则化加权系数。

1) 均方误差损失函数可以测量预测值和测量值之间的离散程度, 表示为:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N |\hat{x}_i - x_i|^2 \quad (33)$$

式中: N 为数据集长度; $\hat{x}_i$ 为 xLSTM 预测出的压力值 $x(t)$ 为测得的压力值。

2) 物理信息损失函数可以为 xLSTM 预测值提供优化方向以确保预测准确性, 表示为:

$$L_{PHY} = \frac{1}{N} \sum_{i=1}^N \left[\left(\frac{dU(t)}{dt} - (\dot{Q}(t) - \dot{W}(t) + \dot{m}_{in}(t)h_{in} - \dot{m}_{out}(t)h_{out}) \right)^2 \right] \quad (34)$$

3) 正则化损失函数保持时间序列平滑性, 表示为:

$$L_{REG} = \frac{1}{N-1} \sum_{i=1}^N |\hat{x}_{i+1} - x_i|^2 \quad (35)$$

3 实验结果与分析

为验证所提出的 PX-LSTM 的压缩机故障诊断方法的有效性, 本文在真实工业数据集上开展实验, 评估模型在异常检测任务中的性能表现。

3.1 实验平台搭建

数字孪生驱动的离心压缩机故障诊断实验平台由硬件平台和软件平台两部分组成。离心压缩机物理平台如



(a) 离心压缩机物理平台
(a) Centrifugal compressor physics platform



(b) 系统可视化界面
(b) System visualization interface

图 4 离心压缩机平台

Fig. 4 Centrifugal compressor platform

3.2 实验数据集

实验使用的数据来源于某工业离心压缩机的历史运行记录,由现场分布式控制系统(DCS)实时采集,采样频率为 1 Hz,覆盖正常工况及 4 种典型故障工况:轴承磨损、密封泄漏、转子不对中和喘振。为全面表征压缩机关键部件的运行状态,本文选取了与轴系稳定性、结构振动

特性及热力学行为高度相关的多类测点作为分析对象,主要包括压力、温度、质量流量、转速、振动和轴心位移等传感器信号。为验证模型在多工况条件下的鲁棒性,数据采样过程涵盖了压缩机在启停、稳态运行及负荷波动下的运行工况,分别用于模型训练与泛化性能评估。传感器设置如表 1 所示。

表 1 传感器设置

Table 1 Sensor settings

传感器类型	测量变量	安装位置	主要作用
压力传感器	$P_{in}、P_{out}$	进气口/出气口近叶轮前后	计算压差、判断压缩比,用于判断喘振、堵塞等故障
温度传感器	$T_{in}、T_{out}$	进气管/出气管内壁	计算比焓,构建热力模型
质量流量计	$\dot{m}_{in}、\dot{m}_{out}$	安装在主进气管与出气管上	监测气体质量流率,用于热力计算
轴承振动传感器	$a(t)$	主轴承盖及侧面	获取振动加速度,识别轴承磨损、不对中等机械故障
轴心位移传感器	$x(t)、y(t)$	主轴两端(X/Y 方向)	监测轴向与径向位移,识别不对中及转子弯曲
转速传感器	$n(t)$	主轴两端	实时监测转速,用于工况区域判别

3.3 评价指标

为了更直观和全面地评估 PX-LSTM,这里采用准确性(Accuracy)、精确率(Precision)、召回率(Recall)、F1 分数(F1 Score)和混淆矩阵(confusion matrix)作为实验结果的衡量指标。在时序数据异常检测中,Accuracy 是指模型正确分类的样本所占的比例,用于衡量模型预测的异常和正常样本中正确预测的样本所占总样本数的比例,表示为:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \tag{36}$$

式中: TP 代表真阳性,表示模型能正确地将异常样本预测为异常; TN 代表真阴性,表示模型能正确地将正常样本预测为正常; FP 代表假阳性,表示模型错误地将正常样本预测为异常; FN 代表假阴性,表示模型错误地将异常样本预测为正常。

Precision 表示模型在预测为异常的样本中,真正异

常的比例,反映其异常预测的准确性。精确率越高,说明模型误报越少。Precision 计算公式如下:

$$Precision = \frac{TP}{TP + FN} \tag{37}$$

Recall 是衡量模型在所有实际异常样本中,能够正确识别出多少异常样本的指标,反映了模型的敏感性,即模型有多擅长找出所有真正的异常,表示为:

$$Recall = \frac{TP}{TP + FN} \tag{38}$$

F1-score 作为二者的调和平均值,能够同时衡量模型的精确性和敏感性。F1-score 的计算公式如下:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{39}$$

F1-score 的值介于 0 和 1 之间。值越接近 1,表示模型在精确率和召回率之间取得了良好的平衡,表现越好。混淆矩阵是一种用于评价分类模型性能的重要工

具,尤其在多类别分类问题中具有直观且全面的效果展示能力。它通过对比模型预测结果与实际真实标签,统计出不同类别之间的分类正确与错误情况,以矩阵形式展示出来。

3.4 对比试验

为验证本文提出的方法相比当前主流智能诊断方法的有效性,这里将所提出的 PX-LSTM 故障诊断方法与多种典型诊断模型进行比较,对比模型包括传统的支持向量机(SVM)、反向传播神经网络(BPNN)、深度域适应网络(DANN)、双向长短期记忆网络(bidirectional long short-term memory network, BiLSTM)、卷积-长短期记忆混合模型(convolutional neural network-long short-term memory network, CNN-LSTM)以及最近提出的 xLSTM,如表 2 所示。

表 2 不同模型故障诊断准确率
Table 2 Fault diagnosis accuracy of different models

模型	Accuracy		无故障	轴承磨损	密封泄漏	转子不对中	喘振
SVM	0.945 6	Precision	0.980 4	0.935 5	0.935 5	0.919 4	0.964 9
		Recall	0.925 9	0.966 7	0.966 7	0.950 0	0.916 7
		F1	0.952 4	0.950 8	0.950 8	0.934 4	0.940 2
SVR	0.881 0	Precision	0.877 2	0.948 3	0.880 0	0.763 9	0.964 9
		Recall	0.925 9	0.916 7	0.733 3	0.916 7	0.916 7
		F1	0.900 9	0.932 2	0.800 0	0.833 3	0.940 2
BPNN.	0.969 4	Precision	0.980 8	0.966 7	0.967 2	0.951 6	0.983 1
		Recall	0.944 4	0.966 7	0.983 3	0.983 3	0.966 7
		F1	0.962 3	0.966 7	0.975 2	0.967 2	0.974 8
DANN	0.952 4	Precision	0.912 3	0.963 6	0.950 8	0.936 5	1.000 0
		Recall	0.963 0	0.883 3	0.966 7	0.983 3	0.966 7
		F1	0.936 9	0.921 7	0.958 7	0.959 3	0.983 1
BiLSTM	0.9626	Precision	0.963 0	0.983 1	0.950 8	0.936 5	0.982 5
		Recall	0.963 0	0.966 7	0.966 7	0.983 3	0.933 3
		F1	0.963 0	0.974 8	0.958 7	0.959 3	0.957 3
xLSTM	0.969 4	Precision	0.980 8	0.967 2	0.966 7	0.951 6	0.983 1
		Recall	0.944 4	0.983 3	0.966 7	0.983 3	0.966 7
		F1	0.962 3	0.975 2	0.966 7	0.967 2	0.974 8
CNN-LSTM	0.972 8	Precision	0.963 0	0.983 3	0.967 2	0.967 2	0.982 8
		Recall	0.963 0	0.983 3	0.983 3	0.983 3	0.950 0
		F1	0.963 0	0.983 3	0.975 2	0.975 2	0.966 1
PX-LSTM	0.976 2	Precision	0.980 8	0.967 2	0.983 3	0.967 7	0.983 1
		Recall	0.944 4	0.983 3	0.983 3	1.000 0	0.966 7
		F1	0.962 3	0.975 2	0.983 3	0.983 6	0.974 8

如图 5 所示,SVM、SVR 在轴承磨损、转子不对中等特征相近的故障类型之间存在一定程度的误分类现象,说明其对复杂非线性时序特征的表达能力有限。BPNN、DANN、BiLSTM、xLSTM 及 CNN-LSTM 在整体分类性能上均优于传统方法;但在部分故障类别上仍存在误判,特别是在工况变化较大时,其在特征相似的故障状态之间易产生误判。本文提出的 PX-LSTM 在混淆矩阵中表现出最清晰的对角线分布,预测结果与真实标签高度一致,几

本文提出的 PX-LSTM 故障诊断方法在 5 类工况下的 Precision、Recall 和 F1-score 均保持较高且稳定的水平,特别是在转子不对中和密封泄漏等易混淆故障情况下表现出更强的故障判别能力。实验结果表明将热力学约束嵌入模型训练过程,有助于提升故障诊断结果的可靠性与一致性。具体来看,PX-LSTM 模型在整体分类准确率上达到 97.62%,优于所有对比模型,尤其相比传统机器学习方法如 SVM(94.56%)和 SVR(88.10%)具有明显提升;在具体故障类型的识别中,PX-LSTM 相较于两种具有代表性的神经网络模型 BPNN 与 DANN 表现出更强的稳定性和边界识别能力;相较于 BiLSTM、xLSTM、CNN-LSTM 等深度序列网络,PX-LSTM 能在保持时序建模能力的同时,融合物理约束特征,更有效地捕捉关键故障演化模式。

乎未出现系统性混淆,说明引入热力学物理约束后,模型能够有效抑制无物理意义的特征干扰,提升故障类别间的可分性。此外,如图 6 所示,针对 Precision、Recall 和 F1-score 3 个指标,基于模型的诊断性能进行综合对比。可以看出,BPNN、DANN 和 xLSTM 虽然在 Precision 或 Recall 单一指标上取得较高数值,但存在指标间不平衡的问题;PX-LSTM 在 3 项指标上均保持较高且相对均衡的表现,说明其在多工况条件下展现出更好的综合诊断能力。




图 5 不同模型故障诊断分类结果混淆矩阵

Fig. 5 Confusion matrix of fault diagnosis classification results of different models

3.5 泛化实验

离心压缩机设备的运行工况复杂多变,采集信号的

特征存在明显差异。为系统评估所提出的 PX-LSTM 模型在变工况条件下的泛化能力,这里设计泛化性能实验,




图 6 不同模型结果评价指标对比
Fig. 6 Comparison of evaluation indicators of different model results

对比分析 PX-LSTM 与多种典型故障诊断模型 (SVM、BPNN、DANN、BiLSTM、xLSTM、CNN-LSTM) 在不同工况数据集下的表现。所有模型均在统一的数据预处理和评估标准下进行训练与测试, 评估指标包括 Precision、Recall 和 F1-score, 以全面反映各模型在分类准确性、召回能力及综合性能方面的表现, 验结果如表 3 和 4 所示。实验结果可以看出, 传统机器学习方法在跨工况数据集测试时整体性能下降明显, 对比模型 SVM 与 BiLSTM 的性能下降幅度超过了 8.5%; 而 PX-LSTM 仅下降 1.2%, 展现出良好的泛化性能, 且 PX-LSTM 在两个数据集上的 Precision、Recall 和 F1-score 3 项指标的表现都较为优异且均衡, 充分验证了其在离心压缩机故障诊断任务中的工程可行性与应用潜力。

表 3 数据集 1 下不同模型故障诊断准确率

Table 3 Fault diagnosis accuracy of different models under dataset 1

模型	Precision	Recall	F1
SVM	0.964 9	0.916 7	0.940 2
SVR	0.763 9	0.916 7	0.833 3
BPNN	0.951 6	0.983 3	0.967 2
DANN	0.913 8	0.981 5	0.946 4
BiLSTM	0.951 6	0.983 3	0.967 2
xLSTM	0.983 1	0.966 7	0.974 8
CNN-LSTM	0.962 3	0.944 4	0.953 3
PX-LSTM	0.982 8	0.950 0	0.966 1

表 4 数据集 2 下不同模型故障诊断准确率
Table 4 Fault diagnosis accuracy of different models under dataset 2

模型	Precision	Recall	F1
SVM	0.935 5	0.966 7	0.950 8
SVR	0.877 2	0.925 9	0.900 9
BPNN	0.909 1	0.925 9	0.917 4
DANN	0.942 3	0.907 4	0.924 5
BiLSTM	0.962 3	0.944 4	0.953 3
xLSTM	0.982 8	0.950 0	0.966 1
CNN-LSTM	0.967 2	0.983 3	0.975 2
PX-LSTM	0.980 8	0.944 4	0.962 3

4 结 论

针对当前离心压缩机实时故障诊断与可视化监测问题,提出了 PX-LSTM 方法。实验结果表明,将热力学一致性约束引入时序深度模型训练过程,能够有效抑制无物理意义的特征干扰,提高模型在复杂工况下的诊断稳定性与泛化能力;在多模型对比实验中,PX-LSTM 在准确率、精确率、召回率及 F1-score 等指标上均优于传统机器学习方法和纯数据驱动深度模型,尤其在易混淆故障的识别中表现出更清晰的判别边界;泛化实验结果进一步表明,基于数字孪生的虚实协同建模能够有效缓解工业数据分布变化对模型性能的影响,为复杂工业装备的长期稳定运行提供可靠支撑。本文为物理信息驱动的数字孪生智能诊断算法在离心压缩机等复杂旋转机械中的工程应用提供了可行路径,同时为数字孪生技术在压缩机故障诊断领域的应用提供了新的思路与方法。

参考文献

[1] Golmoradi M, Ebrahimi E, Javidan M. Compressor fault diagnosis based on SVM and GA[J]. *Vibroengineering Procedia*, 2017, 12: 49-53.

[2] Wang Q F, Liu J H, Wei B K, et al. Investigating the construction, training, and verification methods of k-means clustering fault recognition model for rotating machinery [J]. *IEEE Access*, 2020, 8: 196515-196528.

[3] Tao H F, Qiu J E, Chen Y Y, et al. Unsupervised cross-domain rolling bearing fault diagnosis based on time-frequency information fusion [J]. *Journal of the Franklin Institute*,2023, 360(2): 1454-1477.

[4] Dixit S, Verma N K, Ghosh A K. Intelligent fault diagnosis of rotary machines; Conditional auxiliary classifier GAN coupled with meta learning using limited

data [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.

[5] Gribbestad M, Hassan M U, Hameed I A, et al. Health monitoring of air compressors using reconstruction-based deep learning for anomaly detection with increased transparency[J]. *Entropy*, 2021, 23(1): 83.

[6] Tian H X, Li R J, Yang L Z. Operation status monitoring of reciprocating compressors based on the fusion of spatio-temporal multiple information [J]. *Measurement*, 2022, 204: 112087.

[7] Gao Y, Zhang L, Zhou J W, et al. Research on reliability of centrifugal compressor unit based on dynamic Bayesian network of fault tree mapping [J]. *Journal of Mechanical Science and Technology*, 2023, 37(5): 2667-2677.

[8] Pu L M, Zhang L, Liu J, et al. Industrial compressor-monitoring data prediction based on LSTM and self-attention model[J]. *Processes*, 2025, 13(2): 474.

[9] Iliută M E, Moisescu M A, Pop E, et al. Digital twin: A review of the evolution from concept to technology and its analytical perspectives on applications in various fields[J]. *Applied Sciences*, 2024, 14(13): 5454.

[10] 谢嘉成,郑子盈,王学文,等. 基于工业元宇宙的综采工作面虚实融合运行模式初步探索 [J]. *煤炭科学技术*,2023,51(10):266-279.

Xie Jiacheng, Zheng Ziyang, Wang Xuewen, et al. Preliminary exploration of virtual-real integrated operation mode for fully mechanized mining face based on industrial metaverse [J] *Coal Science and Technology*, 2023, 51(10):266-279.

[11] Xu Y, Sun Y M, Liu X L, et al. A digital-twin-assisted fault diagnosis using deep transfer learning [J]. *IEEE Access*, 2019, 7: 19990-19999.

[12] Wang J J, Ye L K. Digital twin for rotating machinery fault diagnosis in smart manufacturing [J]. *International Journal of Production Research*, 2019, 57(12): 3920-3934.

[13] Yang C, Cai B P, Wu Q B, et al. Digital twin-driven fault diagnosis method for composite faults by combining virtual and real data[J]. *Journal of Industrial Information Integration*, 2023, 33: 100469.


[14] Xu Z, Wang Z, Gao C J, et al. A digital twin system for centrifugal pump fault diagnosis driven by transfer learning based on graph convolutional neural networks [J]. *Computers in Industry*, 2024, 163: 104155.

- [15] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [16] 陶飞,程颖,程江峰,等. 数字孪生车间信息物理融合理论与技术[J]. 计算机集成制造系统, 2017, 23(8): 1603-1611.
- Tao Fei, Cheng Ying, Cheng Jiangfeng, et al. Theory and technology of cyber-physical fusion for digital twin workshop [J]. Computer Integrated Manufacturing Systems, 2017, 23(8): 1603-1611.
- [17] 赵春晖, 陈旭. 从分解视角出发: 基于多元统计方法的工业时序建模与过程监测综述[J]. 控制与决策, 2024, 39(11): 3521-3546.
- Zhao Chunhui, Chen Xu. Industrial time series modeling and process monitoring via multivariate statistical decomposition: A review [J]. Control and Decision, 2024, 39(11): 3521-3546.
- [18] Yu W K, Zhao C H. Low-rank characteristic and temporal correlation analytics for incipient industrial fault detection with missing data [J]. IEEE Transactions on Industrial Informatics, 2021, 17(9): 6337-6346.
- [19] 徐瑞东, 侯志鹏. 基于相关因子的工业过程数据缺失值填补研究[J]. 自动化博览, 2021, 38(12): 64-67.
- Xu Ruidong, Hou Zhipeng. Missing Value Imputation for Industrial Process Data Based on Correlation Factors [J]. Automation Panorama, 2021, 38(12): 64-67.
- [20] Chen X, Zhao C H. Linear and nonlinear hierarchical multivariate time delay analytics for dynamic modeling and process monitoring [J]. Journal of Process Control, 2021, 107: 83-93.
- [21] Zhao C H, Sun H, Tian F. Total variable decomposition based on sparse cointegration analysis for distributed monitoring of nonstationary industrial processes [J]. IEEE Transactions on Control Systems Technology, 2020, 28(4): 1542-1549.
- [22] Song Q Y, Jiang X X, Wang S, et al. Self-adaptive multivariate variational mode decomposition and its application for bearing fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [23] Dao F, Zeng Y, Qian J. Fault diagnosis of hydro-turbine

via the incorporation of bayesian algorithm optimized CNN-LSTM neural network [J]. Energy, 2024, 290: 130326.

- [24] Beck M, Pöppel K, Spanring M, et al. XLSTM: Extended long short-term memory [J]. ArXiv preprint arXiv:2405.04517, 2024.

作者简介



陈泰峰, 2012 年于安徽理工大学获得学士学位, 现为国家能源集团泰州发电有限公司工程师, 主要研究方向为火电机组灰、渣、硫、碳捕集设备检修维护。

E-mail: 907917566@qq.com

Chen Taifeng received his B. Sc. degree from Anhui University of Science and Technology in 2012. Now he is an engineer in China Energy Investment Corporation Taizhou Power Generation Co., Ltd. His main research interests include maintenance and repair of ash, slag, sulfur, and carbon capture equipment for thermal power units.



程雨, 2020 年于郑州大学获得学士学位, 现为中国石油大学(北京)硕士研究生, 主要研究方向为深度学习、数字孪生和故障诊断。

E-mail: 2024211260@student.cup.edu.cn

Cheng Yu received her B. Sc. degree from Zhengzhou University in 2020. Now she is a M. Sc. candidate in China University of Petroleum (Beijing). Her main research interests include deep learning, digital twins and fault diagnosis.



连远锋(通信作者), 2000 年于长春工业大学获得学士学位, 2003 年于长春工业大学获得硕士学位, 2012 年于北京航空航天大学获得博士学位, 现为中国石油大学(北京)教授, 主要研究方向为人工智能、深度学习、数字孪生和大模型。

E-mail: lianyuanfeng@cup.edu.cn

Lian Yuanfeng (Corresponding author) received his B. Sc. degree from Changchun University of Technology in 2000, M. Sc. degree from Changchun University of Technology in 2003, and Ph. D. degree from Beijing University of Aeronautics and Astronautics in 2012, respectively. Now he is a professor in China University of Petroleum (Beijing). His main research interests include artificial intelligence, deep learning, digital twins, and large models.