

DOI: 10.19650/j.cnki.cjsi.J2514649

面向泥泵封水系统的压力传感器可解释性故障 诊断及健康状态评估*

龙哲诚^{1,2}, 张鹏³, 陈容钦³, 危卫⁴, 范世东⁴

(1. 武汉理工大学三亚科教创新园 三亚 572000; 2. 武汉理工大学船海与能源动力工程学院 武汉 430063;
3. 中交广州航道局有限公司 广州 510220; 4. 武汉理工大学交通与物流工程学院 武汉 430063)

摘要:针对疏浚船舶泥泵封水系统中压力传感器性能衰退和失效的问题,构建了一种融合封水泵水力物理规律与数据驱动的可解释性故障诊断与健康评估框架。首先依据封水泵水力特性构建封水压力物理模型,用以推导泵出口位置的封水压力,并将该理论压力作为独立于传感器健康状态的物理真实参照;考虑到设备在长期运行中存在非线性劣化与参数偏移,进一步引入动态优化的幂指数拟合系数,以提升该物理模型在不同工况下的适应性与精度;构建融合物理信息约束的多尺度卷积-Transformer注意力融合网络,通过分段动态损失权重调度实现物理一致性与数据拟合精度的协同优化,从而显著提升封水压力预测的准确性与复杂工况下的泛化能力。基于理论压力、模型预测压力与传感器实测压力之间的残差变化构建阈值判别机制,实现对瞬时性、间歇性与永久性故障的可解释识别;同时提出多参数融合的可信度计算方法,用于量化压力传感器从健康、初期异常、加速劣化至功能失效的全寿命退化轨迹,可信度曲线能够准确呈现“平缓—加速—骤降”的退化演化特征。基于实船运行数据的仿真结果表明,所提方法在预测精度、稳定性及收敛性方面均优于对比模型, R^2 高达0.9527,并能在健康阶段识别短时异常,实现对压力传感器的高可信度故障诊断与智能运维支撑。

关键词:泥泵封水系统;物理信息神经网络;压力传感器故障诊断;可信度计算;健康评估

中图分类号: TH868 TH311 **文献标识码:** A **国家标准学科分类代码:** 510.40

Towards explainable fault diagnosis and health state assessment of pressure sensors in mud pump sealing water system

Long Zhecheng^{1,2}, Zhang Peng³, Chen Rongqin³, Wei Wei⁴, Fan Shidong⁴

(1. Sanya Science and Education Innovation Park, Wuhan University of Technology, Sanya 572000, China; 2. School of Naval Architecture, Ocean and Energy Power Engineering, Wuhan University of Technology, Wuhan 430063, China; 3. CCCC Guangzhou Dredging Co., Ltd., Guangzhou 510220, China; 4. School of Transportation and Logistics Engineering, Wuhan University of Technology, Wuhan 430063, China)

Abstract: To address the degradation and failure of pressure sensors in the sealing water system of dredger mud pumps, an interpretable fault diagnosis and health assessment framework that integrates hydraulic physical principles of sealing pumps with data-driven modeling is established. Firstly, a physical model of sealing water pressure is constructed based on the hydraulic characteristics of the sealing water pump to derive the sealing water pressure at the pump outlet, which serves as a physically grounded reference independent of the sensor health state. Considering the nonlinear degradation and parameter drift of the equipment during long-term operation, dynamically optimized power-law fitting coefficients are further introduced to improve the adaptability and accuracy of the physical model under different operating conditions. A multi-scale convolution-Transformer attention fusion network incorporating physical information constraints is developed, where a piecewise dynamic loss-weight scheduling strategy is introduced to achieve synergistic optimization between physical consistency and data-driven fitting accuracy, thereby significantly enhancing sealing-water-pressure prediction accuracy.

收稿日期: 2025-11-05 Received Date: 2025-11-05

* 基金项目: 国家自然科学基金(52071240)项目资助

and improving generalization capability under complex operating conditions. Based on the residual variations among the theoretical pressure, the model-predicted pressure, and the sensor-measured pressure, a threshold-based discrimination mechanism is established to realize explainable identification of transient, intermittent, and permanent faults. Meanwhile, a multi-parameter fusion reliability calculation method is proposed to quantify the full-life degradation trajectory of the pressure sensor from a healthy state to initial abnormality, accelerated deterioration, and functional failure, and the reliability curve can accurately present the degradation evolution characteristic of "slow-accelerated-sharp decline". Simulation results based on real vessel operation data show that the proposed method outperforms the comparison models in prediction accuracy, stability, and convergence, with R^2 up to 0.952 7, and can identify short-term anomalies in the healthy stage, realizing high-confidence fault diagnosis and intelligent maintenance support for pressure sensors.

Keywords: mud pump sealing water system; physics-informed neural network; pressure sensor fault diagnosis; reliability calculation; health assessment

0 引言

疏浚工程是港口建设、航道维护、深海采矿等领域的重要支撑。其中,绞吸式挖泥船因连续作业能力强,具有用途广泛、操作简单且经济性好等优点,成为当前疏浚工程的主力船型^[1]。随着疏浚船舶大型化及高排距、高扬程施工需求的提升,其关键装备泥泵的功率不断增大,导致其在运行期间易出现加速性能衰退甚至发生故障。泥泵封水系统是保障泥泵健康运行、延长使用寿命的关键组成,其主要功能是防止泥浆颗粒进入叶轮与耐磨板间隙、泵轴密封及吸入端密封,降低泥泵磨损^[2]。在该系统中,封水压力传感器作为核心监测元件,负责实时测量轴端与吸入端封水压力,确保其始终高于泵腔压力,实现封水稳定控制。作为封水系统状态反馈与自动调节的重要依据,其感知数据直接影响封水泵的精准调控与泥泵安全运行。然而,泥泵封水系统的压力传感器长期暴露于强振动、高湿度与高盐度等恶劣海工环境中,极易发生性能衰退或失效,导致压力监测偏差甚至错误报警。一旦传感器输出异常,将无法维持足够封水压力,可能引发叶轮间隙异常磨损、密封失效,甚至造成施工中断^[3]。因此,提升压力传感器故障诊断与健康监测能力,是保障封水系统稳定运行、避免重大设备故障及提升泥泵智能化水平的关键技术手段。通过精准识别传感器偏差或退化状态,可为控制系统提供经过可信校验的压力信息,支持及时调整封水泵转速、封水压力等控制策略,从而确保泥泵在复杂工况下的高效与安全运行。

近年来,传感器故障诊断技术发展迅速,常见方法主要包括:基于机理模型的方法、基于解析模型的方法以及基于数据驱动的诊断方法^[4-7]。其中,基于机理模型的方法依托系统的物理与化学机制建立精确数学模型,通过比较模型预测值与实际测量值之间的偏差来识别故障^[8]。然而,对于泥泵封水系统等运行工况高度复杂的系统而言,其相关的传感器采集的数据往往受到外界环境噪声和工况波动的影响,使得基于解析或机理模型的

传感器诊断方法构建难度大幅增加。

基于解析模型的方法是利用数学解析手段建立系统行为模型^[9]或区间观测器^[10],通过分析残差或参数偏离来定位故障^[11]。Ahmad等^[12]基于观测器的残差发生器与状态反馈控制器结合用于对双旋翼气动系统的输出传感器进行故障检测。但是,在实际的疏浚施工过程中,信号的抗干扰能力弱,单一地依赖解析模型生成的残差可能被噪声掩盖或混淆,降低故障检测的灵敏度和可靠性。在此背景下,基于数据驱动的传感器故障诊断方法逐渐受到关注。该方法通过直接从传感器数据中挖掘潜在特征和异常模式,实现对传感器性能衰退或失效的识别,已成为传感器故障诊断研究的核心方向。

基于数据驱动的方法依赖历史数据中的统计规律,利用机器学习或深度学习技术直接从数据中提取故障特征,无需先验物理知识^[13-17],常用方法包括贝叶斯优化^[18]、卡尔曼滤波^[19]和深度残差网络^[20]等。蒋栋年等^[21]提出了一种基于测量数据统计相关性的方法,实现了在有参考值和无参考值情况下的传感器自诊断。Hosseini Lavassani等^[22]结合深度信号异常检测、一维卷积神经网络及支持向量回归算法,实现结构健康监测系统中故障传感器数据的检测、分类与重建。熊伟等^[23]通过虚拟电流预测器与滑动时间窗口构建电流残差,实现传感器间歇性故障的诊断及健康评估。但此类虚拟预测器方法存在黑箱性与可解释性不足的问题。为提高诊断精度与可靠性,基于物理约束的机器学习方法逐渐成为研究热点,其中物理信息神经网络(physics-informed neural network, PINN)通过将物理定律嵌入训练过程,有效融合机理模型与数据驱动模型优势,增强了模型可解释性与泛化能力^[24-26]。

泥泵封水系统中,封水压力传感器作为关键控制信号,其数据精确性对系统的控制至关重要。在全寿命周期中,传感器通常经历4个阶段:1)早期运行稳定、数据精准为健康阶段;2)随施工推进出现短时段骤升或骤降的瞬时性故障为初期异常阶段;3)异常信号持续一段时间后恢复的间歇性故障为加速劣化阶段;4)异常信号长时

间持续且无恢复迹象的永久性故障为失效阶段,需要及时更换。因此,实现对传感器不同状态的精准识别与健康状态的动态评估,是确保感知信号准确获取、提升封水控制系统精准调控能力的关键所在,对保障泥泵安全、高效运行具有至关重要的意义,也是当前智能化疏浚装备领域研究的核心问题。

综上所述,针对泥泵封水系统压力传感器异常问题,构建了一种基于 PINN 的故障诊断与健康评估方法。首先,构建基于封水泵水力特性的物理模型,并引入动态拟合系数以提升模型精度。其次,设计封水压力 PINN 虚拟预测模型,将物理定律作为约束强制施加于神经网络,通过动态调节物理损失与数据损失权重,实现物理一致性与数据拟合的平衡。随后,融合物理预测值与虚拟预测值,并与实测数据进行残差分析,结合动态滑动窗口可实现可解释的故障诊断。最后,基于故障频次、持续时间及最大故

障时长等指标构建可靠度函数,对传感器健康状态进行动态评估,为疏浚作业连续施工及传感器运维提供指导。

1 系统介绍和故障特征分析

1.1 泥泵封水系统介绍

泥泵封水系统结构如图 1 所示。作业时,泥浆在叶轮离心力作用下由吸入端进入泵体并输送至排泥管。由于叶轮与耐磨板存在间隙,部分泥浆会回流至中心区域并导致局部磨损,随着磨损加剧,间隙扩大,回流恶化,进而引起效率下降与寿命缩短。为抑制回流,需要在轴端和吸入端施加封水。在长期高振动与高强度工况下,叶轮间隙不可避免增大,对封水压力的需求随之提升,因此封水压力的精准感知直接关系到封水系统控制的稳定性及泥泵整体寿命。

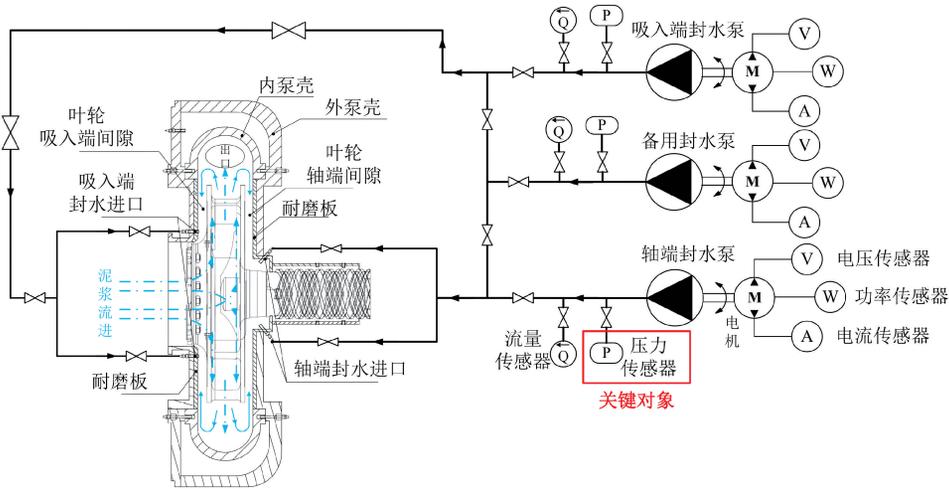


图 1 泥泵封水系统结构

Fig. 1 Diagram of the mud pump sealing water system

1.2 封水压力传感器故障特征分析

疏浚船作业环境通常位于江河湖海,压力传感器长期暴露于恶劣的工作条件下,易发生性能衰退,导致信号偏差、传输中断或异常,常表现为瞬时性、间歇性和永久性故障。瞬时性故障表现为短时随机异常且可自动恢复;间歇性故障表现为异常信号周期性或随机出现且持续时间较长;永久性故障则表现为不可逆的持续异常。为提升压力感知精度,引入基于 PINN 的虚拟传感器模型以提升感知准确性,其训练同时依赖精确的物理机理与感知数据。因此,需对故障特征与数据质量做出合理假设与分析,以此为模型提供可靠的物理约束与数据基础,确保其输出可信。

传感器组故障建模与虚拟诊断机制

系统包含传感器组 $S = \{1, 2, 3, \dots, n\}$, 每个传感器 i

的故障状态由二元变量 $f_i \in \{0, 1\}$, $f_i = 1$ 表示故障, $f_i = 0$ 表示正常。在故障诊断中,虚拟传感器符合以下数学描述,如式(1)和(2)所示。

$$f_i = 1 \Rightarrow (\forall j \in S_i, f_j = 0) \quad (1)$$

$$\hat{x}_i = g(\{x_j | j \in S_i\}) \quad (2)$$

其中, S_i 是传感器 i 的关联传感器集合; $g(\cdot)$ 是基于特征相关性和回归模型的回归预测函数, \hat{x}_i 是预测值, x_j 是传感器 j 的感知值, 如果 $f_i = 1$, 则必须保证 $\forall j \in S_i, f_j = 0$ 。

为刻画故障的时域特性,引入矩形函数表示第 i 次故障的激活状态,如式(3)所示。

$$\text{rect}_{\delta_s}(t - \tau_i^s) = \begin{cases} 1, & \tau_i^s \leq t < \tau_i^s + \delta_s \\ 0, & \text{其他} \end{cases} \quad (3)$$

则总体故障响应可表示如式(4)所示。

$$f(t) = A_i(t) \times \sum_{i=1}^{N_s} \text{rect}_{\delta_s}(t - \tau_i^s) \quad (4)$$

其中, $A_i(t)$ 为第 i 次故障的异常幅值, 当脉冲宽度 $\delta_s = 1$, 表现为瞬时性故障; 当 $\delta_s > 1$ 且可恢复, 则表现为间歇性故障; 当 $\delta_s \rightarrow \infty$, 则表现为永久性故障。

1.3 封水压力物理模型

在泥泵封水系统中, 封水压力可以近似地等同于封水泵的出口压力。根据离心泵功率计算公式分析, 如式(5)和(6)所示。

$$P_p = \frac{\rho g Q_s H}{\eta} \quad (5)$$

$$H = \frac{P_s}{\rho g} \quad (6)$$

其中, P_p 为封水泵实际功率, 单位为 kW; Q_s 为实际的封水流量, 单位为 m^3/h ; P_s 为封水压力, 单位为 bar; H 为扬程, 单位为 m; ρ 为清水介质密度, $\rho = 1000 \text{ kg}/\text{m}^3$; g 为重力加速度, $g = 9.81 \text{ m}/\text{s}^2$; η 为泵效率, 根据实际情况 $\eta = 54\%$ 。

因此通过联立式(5)和(6), 可以得到封水压力的物理计算模型, 如式(7)所示。

$$P_s = \frac{P_p \eta}{Q_s} \quad (7)$$

在封水系统中, 流量、压力与功率之间存在强耦合关系, 但是, 由于封水泵在长期运行中因磨损与效率衰减表现出显著的退化效应, 导致传统经验式(7)难以准确刻画实际工况。为此, 在物理模型基础上引入动态扰动项 ε , 并对流量、功率和效率设置动态拟合系数 β 、 α 和 γ , 以刻画设备非线性退化引起的参数偏移。该方法既能在保持物理可解释性的同时补偿模型与真实运行之间的偏差, 又提升了预测精度与鲁棒性, 参考公式如式(8)所示。

$$P_s = \varepsilon \frac{P_p^\alpha \eta^\gamma}{Q_s^\beta} \quad (8)$$

2 可解释性压力传感器故障诊断模型

2.1 可解释性的传感器故障诊断结构

为提升泥泵封水系统压力传感器故障诊断模型的可信度、可解释性与工程适应性, 构建了融合物理规律与深度特征学习的可解释智能诊断框架。首先, 将封水系统能量守恒方程嵌入多尺度卷积神经网络-Transformer (multi-scale convolutional neural network-Transformer, MCNN-Transformer) 的损失函数, 形成具有物理约束的 PINN 结构, 并通过差分进化算法自适应优化关键物理参数, 实现物理机理与数据特征的协同建模, 增强模型

对不同劣化阶段的物理一致性表达。其次, 提出分段动态权重调度策略, 使模型在训练初期以物理约束限制解空间、促进快速收敛, 后期以数据驱动细化预测, 从而实现物理一致性与拟合精度的双重提升。最后, 构建基于物理-虚拟融合残差的可解释故障诊断与健康评估方法, 通过残差统计与可靠度建模量化传感器全寿命退化过程, 实现从异常检测到健康度评估的闭环决策支持, 有效避免传统方法的“黑箱化”问题。整体方法架构如图2所示。

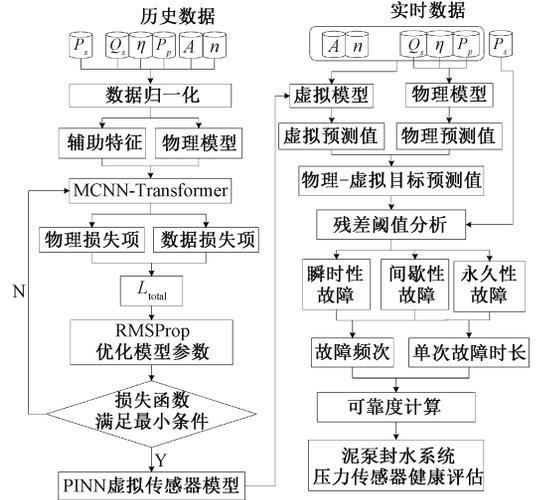


图2 泥泵封水系统压力传感器故障诊断结构
Fig. 2 Fault diagnosis structure for pressure sensors in the sealing water system of mud pump

其具体的步骤为:

- 1) 采集泥泵封水系统的全部感知参数。基于式(8), 将封水流量、功率和泵效率作为物理约束输入。同时引入封水泵电流和转速这类与封水功率相关的数据作为辅助特征, 进一步提升预测精度和物理可解释性;
- 2) 将物理模型嵌入 MCNN-Transformer 损失函数, 形成基于 PINN 的虚拟传感器训练框架, 通过权重调度实现物理一致性与预测精度的联合优化;
- 3) 融合虚拟预测值与物理预测值, 计算与实测压力的残差序列, 建立残差阈值表决体系实现异常信号的解释性检测;
- 4) 根据残差特征统计故障频次和持续时间, 利用可靠度函数计算压力传感器的健康状态, 为泥泵在连续施工工况下的设备监控与运维提供可解释的智能决策支持。

2.2 基于 PINN 的虚拟压力传感器模型

本研究采用的 PINN 模型是基于 MCNN-Transformer 模型, PINN 模型的结构原理如图3所示, 其中 MCNN-Transformer 模型如图4所示。

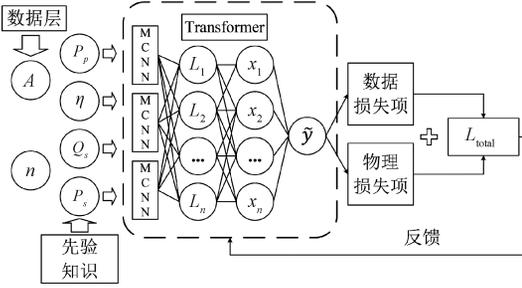


图 3 PINN 结构原理

Fig. 3 Diagram of PINN structure

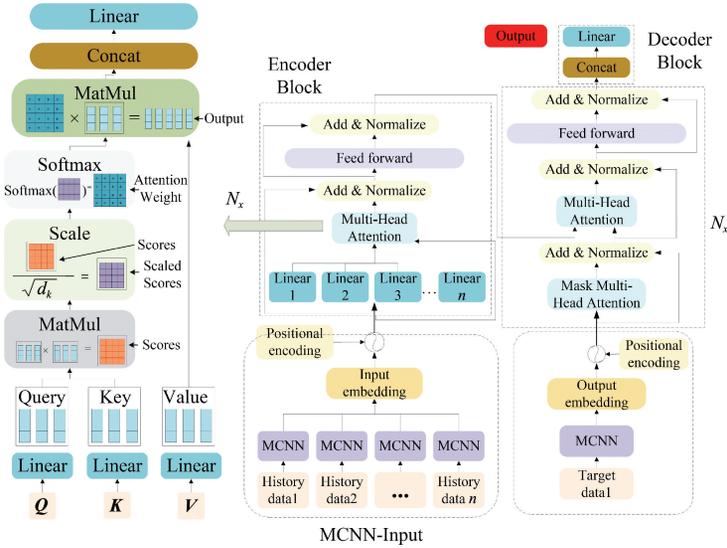


图 4 MCNN-Transformer 结构

Fig. 4 MCNN-Transformer architecture

其中, A 和 n 是电流和转速,代表辅助特征参数, P_p 、 Q_s 、 η 和 P_s 为基于先验物理知识映射到 PINN 模型中的输入和输出变量,该模型可表示如式(9)所示。

$$\hat{P}_s = PN(P_p^\alpha, \eta^\gamma, Q_s^\beta, A, n; \vartheta) \quad (9)$$

其中, PN 代表物理信息神经网络; ($P_p^\alpha, \eta^\gamma, Q_s^\beta, A, n; \vartheta$) 代表拟合系数下的物理信息初值先验和辅助参数, ϑ 代表神经网络网络架构参数及权重。

训练过程的总损失如式(10)所示。

$$L_{total} = \lambda L_{data} + (1 - \lambda) L_{physic} \quad (10)$$

式中: L_{data} 是基于 MCNN-Transformer 算法的数据损失项; L_{physic} 是通过物理模型计算的物理损失项; λ 为权重系数,通过动态调节权重系数 λ , PINN 模型可在训练过程中实现物理约束与数据拟合的渐进平衡。训练初期降低 λ 值,强化物理损失,使模型输出满足封水系统基本方程,建立物理一致性;后期增大 λ 值提升数据损失权重,使模型专注于学习传感器数据中的非线性规律。该机制兼顾物理可解释性与数据驱动灵活性,同时加速收敛并增强有限数据条件下的泛化能力与鲁棒性。

2.3 基于物理-虚拟数据叠加残差的故障诊断及健康评估

基于虚拟压力传感器模型得到的封水压力预测值输入至故障诊断模块,将实际的封水压力传感器的数据与物理-虚拟数据叠加的预测值进行对比分析,设置残差阈值进行故障诊断,如式(11)和(12)所示。

$$L_T = \frac{|y_r - y_p|}{y_r} \quad (11)$$

$$y_p = 0.5 \times y_{data} + 0.5 \times y_{physic} \quad (12)$$

其中, y_{physic} 是通过式(8)所计算出的物理预测值; y_{data} 是通过基于 PINN 的虚拟传感器模型得到的预测值,将两者各取 0.5 的权重,得到混合预测值 y_p 后,将 y_p 与实际感知的封水压力 y_r 进行残差阈值分析,若阈值 $L_T > 0.2$,则判定当前感知数据为异常数据,将该次异常记录并传输至泥泵封水感知系统健康评估模型,用于对泥泵封水感知系统健康状态进行评估。

根据假设可对第 i 个窗口的异常指示量定义,如式(13)所示。

$$\tau_i = \begin{cases} 1, & \text{第 } i \text{ 个窗口为异常} \\ 0, & \text{第 } i \text{ 个窗口为正常} \end{cases} \quad (13)$$

基于以上故障诊断分析得到的故障发生的次数和单次故障持续时间等信息,构建的式(14)~(20)用于计算该传感器的可靠度,即:

$$S = a \times \ln(1 + N) + \omega_t \times \ln(1 + T) + \omega_m \times \ln(1 + M) \quad (14)$$

$$N = \sum_{i=1}^n 1 \{ \tau_i = 1 \wedge \tau_{i-1} = 0 \} \quad (15)$$

$$T = \sum_{i=1}^n \tau_i \quad (16)$$

$$M = \max d_i \quad (17)$$

$$s_h = a \times \ln(1 + N_h) + \omega_t \times \ln(1 + T_h) + \omega_m \times \ln(1 + M_h) \quad (18)$$

$$S_0 = \frac{s_h}{(-\ln R_h)^{\frac{1}{q}}} \quad (19)$$

$$R = e^{-\left(\frac{S}{S_0}\right)^q} \quad (20)$$

其中, S 是基于当前故障数据计算的综合故障严重程度指标; N 为检测区间内的故障次数; $1\{\cdot\}$ 为指示函数, 条件成立时取 1, 否则取 0; T 为到第 i 个窗口为止的累计故障窗口数; M 为检测区间内最大连续故障持续窗口数; N_h 、 T_h 和 M_h 分别为传感器健康阶段检测到的故障次数、故障总窗口数和最大连续故障持续窗口数, 反映健康期的正常波动; d_i 为每次故障发生的时长; R_h 为健康状态下传感器的可靠度, $R_h = 0.995$; $a = 0.12$, 用于控制故障次数 n 的影响, 避免早期正常波动导致 R 下降过快; $\omega_t = 0.5$, 用于控制总故障窗口 T , 反映累计程度; $\omega_m = 0.03$, 用于控制最大连续故障 M , 弱化其在前期偶然出现的影响, 也能保证其后期出现长时间故障时可靠度计算值会下降较快; $q = 3.4$, 控制曲线陡峭度, 使其覆盖“早期慢→中期缓→后期加速”的趋势。

封水压力传感器健康状态被划分为健康、初期异常、加速劣化和功能失效这 4 个阶段。通过计算系统可靠度并依据表 1 阈值区间, 可准确识别传感器所处阶段, 对应无故障、瞬时性故障、间歇性故障与永久性故障这 4 类典型模式, 实现故障的早期识别与状态连续评估。

表 1 故障阶段阈值区间

Table 1 Fault stage threshold interval

阶段	故障特征	阈值区间
健康阶段	无	$\{\xi_1, 1\}$
初期异常阶段	瞬时性故障	$\{\xi_2, \xi_1\}$
加速劣化阶段	间歇性故障	$\{\xi_3, \xi_2\}$
功能失效阶段	永久性故障	$\{\xi_4, \xi_3\}$

3 模型验证与分析

为验证上述基于 PINN 的虚拟压力传感器模型预测结果的准确性, 以及可解释性故障诊断算法的有效性和诊断效果, 重点针对疏浚挖泥船泥泵封水系统中的封水压力传感器的数据进行验证。

3.1 实验数据与模型配置

1) 数据来源及预处理

通过实地调研, 收集了中交广州航道局有限公司的“华安龙”绞吸式挖泥船在 2022 年 11 月份的实时监测数据, 共采集了 6 个维度(列)和 26 356 个数据(行)的滑动窗口数据集进行分析, 并以其中的封水压力传感器作为验证对象进行故障诊断算法的验证。

为消除异常测点的干扰, 对原始数据进行剔除缺失值与异常值; 过滤 <0 的无效记录; 以及对有效数据采用 min-max 归一化处理, 以保证输入特征在统一尺度上训练, 如式(21)所示。

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

其中, $x'_i \in [0, 1]$ 表示特征值被线性映射至统一尺度区间。本研究对所有输入特征及输出目标均采用同一归一化策略, 分别通过输入归一化器 Scaler_x 与输出归一化器 Scaler_y 实现, 并在模型推断后通过逆归一化恢复为实际物理量级。

2) 特征筛选依据

依据封水系统的物理机理式(8)明确封水压力 P_s 、功率 P_p 和流量 Q_s 具有最直接的物理耦合关系, 因此选取二者为核心输入特征; 同时考虑转速与电流对功率的间接影响, 将其作为辅助特征输入模型。最终输入特征维度为 4, 输出为封水压力预测值。

3) 滑动窗口构造

为充分捕获封水系统压力信号的时间依赖性与动态演化特征, 本研究采用滑动窗口法(sliding window method, SWM)对归一化后的序列数据进行样本重构。

假设原始时间序列如式(22)所示。

$$X = \{x_1, x_2, x_3, \dots, x_T\}, x_T \in \mathbb{R}^d \quad (22)$$

其中, T 表示总时间步数, d 为输入特征维度(本研究中即功率、流量、转速、电流)。

通过 SWM 构造长度为 L 的输入子序列与预测目标 y_i , 如式(23)所示。

$$\begin{cases} y_i = x_{i+L}^{(\text{target})} \\ X_i = \{x_i, x_{i+1}, x_{i+2}, \dots, x_{i+L-1}\} \end{cases} \quad (23)$$

设时间窗口长度为 $L=60$, 步长 $s=1$, 则每个样本包含连续 60 个时刻的输入序列, 预测下一时刻的封水压力值。

4) 模型设定

本研究采用模型是物理信息嵌入的 MCNN-Transformer(PINN)框架, 核心超参数如表 2 所示。

3.2 基于拟合系数下的封水压力物理模型精度评估

在泥泵封水系统建模中, 传统物理经验公式虽能描述基本机理, 但实际运行受环境扰动与设备退化影响, 模型参数会随时间偏移。为弥补理想模型与真实系统间的

表 2 模型超参数设定

Table 2 Model hyperparameter settings

参数类别	参数名称	数值/设定	说明
网络结构	输入维度	4	功率、流量、转速、电流
	CNN 分支滤波器数	[32,32,32]	多尺度特征提取
	卷积核大小	[3,3,5]	小中大尺度卷积核
	Transformer 编码层数	2	捕获全局依赖关系
	注意力头数	4	多头注意力机制
训练参数	优化器	RMSprop $P=0.9$ $\epsilon=1 \times 10^{-8}$	均方根传播优化器
	学习率	0.001	初始学习率
	批大小	256	
	训练轮数	500	
	丢弃率	0.15	正则化防止过拟合
物理参数	$\alpha, \beta, \gamma, \epsilon$	差分进化求解	提高物理约束模型精度

差异,在物理约束方程中引入 4 个可自适应优化的拟合系数($\alpha, \beta, \gamma, \epsilon$),用于动态修正物理关系,使模型能够表征劣化引起的特征变化。通过在 PINN 框架中利用差分进化算法对其优化,既保证物理一致性,又提升在复杂工况下的适应性与预测可靠性。其表达式如式(24)所示。

$$P_s = \epsilon \frac{P_p^\alpha \eta^\gamma}{Q_s^\beta} \quad (24)$$

该优化方法的核心流程可以归纳为“物理建模→目标函数→幂参数化→全局寻优”,最终通过选择最小化风险函数,确定 $\alpha, \beta, \gamma, \epsilon$ 的最优解,具体如式(25)和(26)所示。

$$\min_{\theta} J(\theta) = \frac{1}{n} \sum_{i=1}^n (\hat{P}_{s,i}(\theta) - P_{s,i})^2 \quad (25)$$

$$\theta = (\epsilon, \alpha, \gamma, \beta) \quad (26)$$

其中, $\hat{P}_{s,i}(\theta)$ 是利用公式计算出的第 i 个封水压力; $P_{s,i}$ 是第 i 个封水压力实际值; θ 为待拟合系数向量。

对该拟合系数采用差分进化(differential evolution, DE)方法进行无导数全局寻优,以对数差作为损失构建适应度函数,如式(27)所示。

$$J_{\log}(\epsilon, \alpha, \gamma, \beta) = \frac{1}{n} \sum_{i=1}^n (\epsilon + \alpha \ln P_{p,i} + \gamma \ln \eta_i - \beta \ln Q_{s,i} - \ln P_{s,i})^2 \quad (27)$$

以式(27)为 DE 优化目标,对 $\alpha, \beta, \gamma, \epsilon$ 进行全局搜索,获得物理方程的最优“幂定律引导系数”,从而

最小化预测与实测之间的偏差。优化结果如表 3 所示。

表 3 物理模型拟合前后精度对比

Table 3 Comparison of accuracy before and after fitting physical models

序	ϵ	α	γ	β	R^2	RMSE
前	1	1	1	1	0.715 9	0.453 0
后	2.100 7	0.999 9	2.976 0	0.870 6	0.985 7	0.101 4

经参数自适应修正后,物理模型的拟合度提升 37.68%,均方根误差降低 77%,显著增强了输入—输出映射能力,提高模型对不同工况变化的适应性,同时进一步促进 PINN 训练阶段的收敛稳定性与预测精度。

3.3 模型机制对比分析

该 3 类模型构成了一条从“纯数据驱动”向“数据—物理融合”的技术演进路径,其核心区别在于特征提取机制、网络结构层级和损失构成模式的逐步增强。

1) Transformer:基于自注意力的全局特征建模

Transformer 模型的预测结构表达式如式(28)所示。

$$\hat{y} = f_T(X) = FFN(MHA(X)) \quad (28)$$

其中, MHA 为多头自注意力层(multi-head attention, MHA); FFN 为前馈神经网络层(feed-forward network, FFN),该基础模型的特点是捕获全局时间依赖,对局部突变、噪声不敏感。

2) MCNN-Transformer:卷积增强建模

MCNN-Transformer 在 Transformer 前加入三路卷积,如式(29)所示。

$$Z = [Conv_{k=3}(X), Conv_{k=3}(X), Conv_{k=3}(X)] \quad (29)$$

卷积融合后再输入 Transformer,如式(30)所示。

$$\hat{y} = f_{M-T}(X) = f_T(Concat(Z)) \quad (30)$$

该模型的特点是可通过卷积网络捕获局部短期特征,增强数据集局部细节表达能力。

3) PINN:融合物理模型约束的混合预测结构

PINN 的预测由数据驱动预测和物理模型预测共同构成,如式(31)和(32)所示。

$$\hat{P}_{data} = f_{M-T}(X) \quad (31)$$

$$\hat{P}_{phys} = \epsilon P_p^\alpha \eta^\gamma Q_s^{-\beta} \quad (32)$$

最后 PINN 的最终训练目标如式(33)所示。

$$L = \lambda \hat{P}_{data} - P_r^2 + (1 - \lambda) \hat{P}_{phys} - P_r^2 \quad (33)$$

其中, P_r 为传感器真实压力; λ 为动态权重。该 PINN 模型的特点是引入物理一致性约束,可修正数据噪声,对退化工况和异常数据具有更强的鲁棒性。

综上所述,3 类模型在结构设计与信息利用方式上呈现由简到繁、由纯数据驱动向数据—物理融合逐步增强的整体趋势;Transformer 结构最为简单,仅依赖注意力机制捕获全局依赖关系,其建模能力与鲁棒性受限;

MCNN-Transformer 在此基础上增加局部卷积特征提取通道,使模型具备同时表征短期波动与长期关联的能力,结构复杂度适中;PINN 则在 MCNN-Transformer 的数据驱动框架上进一步引入物理模型约束与混合损失机制,使模型同时满足物理一致性与数据拟合精度要求,结构最为完整、约束最充分,也是三者中预测能力与稳定性最强的模型。3 类模型的差异体现为:Transformer(最低复杂度)→MCNN-Transformer(中等复杂度)→PINN(最高复杂度但精度最佳)。

3.4 基于 PINN 虚拟压力传感器模型预测评价

为评估虚拟压力传感器模型性能,本研究将健康状态数据随机打乱后按 8:2 划分为训练集与测试集,以避免局部偏差并提升泛化能力。分别在训练集与测试集上验证模型的预测精度与收敛性,精度评价指标包括拟合度(R^2)、均方根误差(root mean square error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE),如式(34)~(36)所示,收敛性则通过损失曲线

的平滑性、收敛速度及最终损失值进行综合分析。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (34)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (35)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \times 100\% \quad (36)$$

其中, n 为样本数量; y_i 为第 i 个样本的真实值; \bar{y}_i 是所有样本真实值的均值; \hat{y}_i 是第 i 个样本的预测值。

如 2.2 节所述,权重系数 λ 是平衡 PINN 中物理约束与数据拟合的关键参数。为验证不同权重策略的性能,将原训练集按 8:2 再划分为内部训练集和验证集,以动态评估模型表现。根据训练前、中、后期对物理与数据驱动的侧重差异,设计 4 种权重调度方案进行对比分析,结果见表 4,其中 e 表示当前迭代次数, E 表示总迭代次数(Epoch)。

表 4 权重配比精度分析

Table 4 Accuracy analysis of weight ratio

序号	权重配比情况	训练集 R^2	测试集 R^2	训练集 MSE	测试集 MSE
1	$\lambda = \begin{cases} 0.1, & 0 < e \leq 0.5E \\ 0.8, & 0.5E < e \leq E \end{cases}$	0.993 0	0.992 4	0.005 2	0.005 0
2	$\lambda = \begin{cases} 0.1, & 0 < e \leq 0.5E \\ 0.9, & 0.5E < e \leq E \end{cases}$	0.869 5	0.837 4	0.079 8	0.075 3
3	$\lambda = \begin{cases} 0.1, & 0 < e \leq 0.7E \\ 0.9, & 0.7E < e \leq E \end{cases}$	0.730 1	0.699 0	0.199 1	0.199 0
4	$\lambda = \frac{1}{E}e, \quad 0 < e \leq E$	0.963 3	0.960 8	0.027 1	0.025 9
5	$\lambda = \begin{cases} 0.25, & 0 < e \leq 0.3E \\ 0.50, & 0.3E < e \leq 0.6E \\ 0.75, & 0.6E < e \leq E \end{cases}$	0.957 9	0.955 1	0.031 1	0.029 7

由表 4 可见,权重动态配比情况 1 的预测效果最优,情况 3 效果最差,测试集 R^2 下降约 26.47%。对比情况 1~3 可知,后期若数据损失权重过高或物理约束过弱,会显著削弱模型的泛化性能;情况 2 优于情况 3,说明逐步增加数据权重较突增更有利于训练稳定。情况 4 略优于情况 5,表明前期强化物理约束可抑制随机初始化引起的过拟合,后期逐步提升数据权重有助于精确拟合。然而,两者均不及情况 1,说明平滑调度不如分段权重策略稳定。总体而言,情况 1 在前期强调物理约束、后期兼顾数据拟合的分段机制下,实现了物理一致性与数据精度的最佳平衡,避免了过度动态调整 λ 引起的收敛波动。

针对不同模型结构特性,PINN 虚拟压力传感器模型采用均方根传播优化器(root mean square propagation, RMSprop)优化器对全部训练参数(权重与偏置)进行更新,而 Transformer 与 MCNN-Transformer 模型采用自适应学习率优化器(adaptive moment estimation, Adam)执行优化过程。由于 PINN 的损失函数同时包含物理损失与数据损失,两类梯度在训练早期存在显著尺度差异,易引起梯度主导失衡与学习率震荡。RMSprop 通过对梯度平方实施指数加权平均,实现对各参数学习率的自适应缩放,可有效缓解混合损失带来的梯度不均衡,从而获得更稳定的收敛行为。相比之下,Transformer 与 MCNN-Transformer 的损失仅由数据误差构成,梯度分布相对平

稳,使用 Adam 即能实现快速且稳定的优化。上述优化器配置旨在确保各类模型在复杂工况数据条件下均具有良好的收敛性与训练稳定性。

在训练集和测试集上对这 3 种模型进行预测精度方面的验证,结果如表 5 和 6 所示。从训练集和测试集的角度看,PINN 的拟合效果均是最佳,MCNN-Transformer 模型效果次之,Transformer 模型效果最差。从测试集的结果来看,相比 Transformer,MCNN-Transformer 的 R^2 提高了约 8.1%,MSE 降低约 49.0%,MAPE 降低约 43.1%,而 PINN 较 MCNN-Transformer 的 R^2 再提升约 2.7%,MSE 继续降低约 34.9%,MAPE 降低约 24.6%。虽然 PINN 的训练时间其他两个模型增加了约 9.4%,但其在精度上的显著优势表明物理约束的引入有效提升了模型的预测性能和泛化能力。

表 5 训练集预测精度对比

Table 5 Comparison of prediction accuracy on the training set

模型	R^2	MSE	MAPE
Transformer	0.873 2	0.093 5	0.061 8
MCNN-Transformer	0.932 9	0.049 5	0.035 6
PINN	0.956 3	0.032 2	0.026 8

表 6 测试集预测精度对比

Table 6 Comparison of prediction accuracy on the training set

模型	R^2	MSE	MAPE
Transformer	0.858 0	0.093 9	0.062 2
MCNN-Transformer	0.927 5	0.047 9	0.035 4
PINN	0.952 7	0.031 2	0.026 7

为了评估不同模型在数据拟合能力和泛化能力的表现,并探究物理约束对模型训练与泛化性能的影响,对 Transformer、MCNN-Transformer 以及 PINN 模型的损失值进行了系统分析,如图 5 和 6 所示。

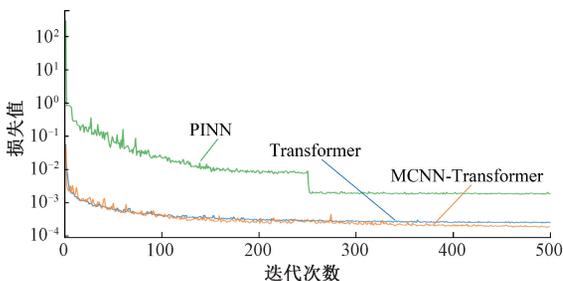


图 5 训练集损失值

Fig. 5 Training loss curve

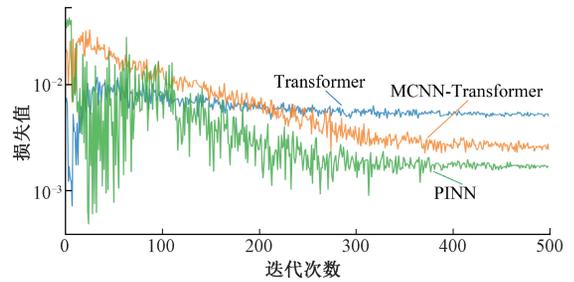


图 6 测试集损失值

Fig. 6 Test loss curve

如图 5 所示,PINN 与 MCNN-Transformer 在训练机制上存在显著差异:PINN 损失由物理约束与数据误差组成,训练初期物理项权重较高,使模型先逼近物理一致解,总损失下降慢且数值高于 MCNN-Transformer。随着训练进入中后期,数据项权重逐步提升,PINN 在保持物理一致性的同时快速降低数据误差,体现出权重调度在平衡物理约束与数据拟合方面的有效作用。从图 6 可见,PINN 在 3 种指标上均优于 MCNN-Transformer,表明物理约束作为强正则化机制能抑制对偶然特征的依赖,使模型学习结果更符合物理规律,并在测试集上实现更高精度与稳健性。

因此,尽管 PINN 在训练集总损失高于纯 MCNN-Transformer,其在测试集上的低损失及全数据集最佳 R^2 、MSE 和 MAPE 表明,物理正则化结合权重调度显著提升了模型泛化能力。这说明,将物理约束融入 MCNN-Transformer 的 PINN 方法能够在保证物理一致性的前提下提高预测精度和稳定性,相较于纯数据驱动方法具有更优综合性能。

3.5 封水压力传感器故障诊断模型验证

为验证所提压力传感器故障诊断方法在工程场景中的有效性,利用绞吸式挖泥船泥泵封水系统全寿命周期运行数据开展验证。采用 SWM 诊断策略实现传感器状态动态评估。结合故障频次、持续性及特征形态,将运行过程划分为健康、初期异常、加速劣化和失效这 4 阶段,并计算各时刻可靠度指标,如图 7~11 所示。其中,图 7~10 的上图为实际值与预测值的封水压力对比,中图为实际与预测值之间的残差,下图为故障检测结果。

如图 7 所示,在健康阶段传感器实际封水压力与物理-虚拟预测值高度一致,残差小且波动平稳,残差比率始终远低于阈值(0.2),仅出现极少瞬时波动,故障检测结果显示其状态稳定,无持续性异常。

如图 8 所示,在初期异常阶段,实际封水压力与预测值之间出现了多处偏差,残差比率多次超过阈值,尤其在 400~600 样本区间波动频繁,结果表明故障主要为瞬时

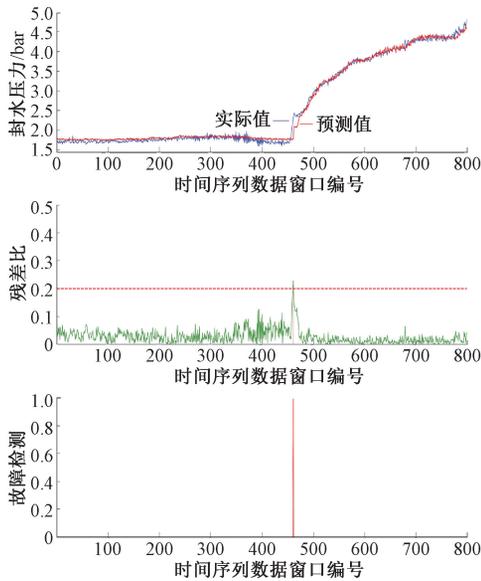


图7 健康阶段压力传感器故障诊断结果

Fig. 7 Fault diagnosis results for the pressure sensor in the healthy stage

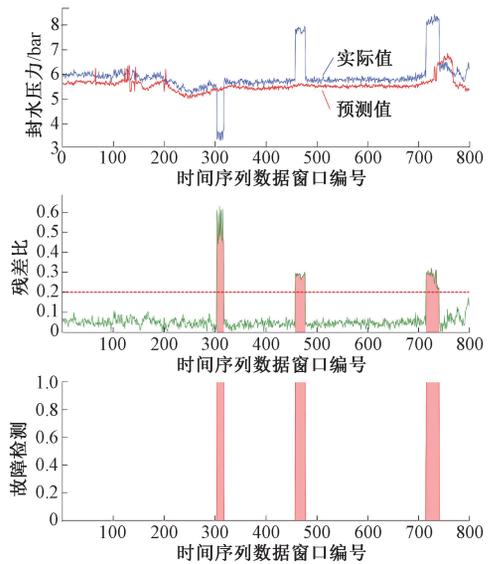


图9 加速劣化阶段压力传感器故障诊断结果

Fig. 9 Fault diagnosis results for the pressure sensor in the accelerated degradation stage

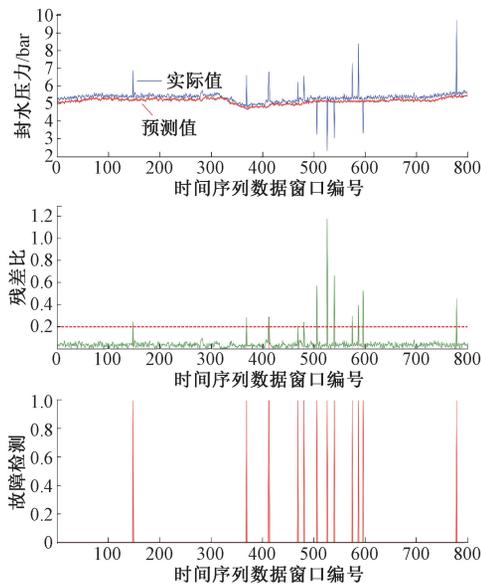


图8 初期异常阶段压力传感器故障诊断结果

Fig. 8 Fault diagnosis results for the pressure sensor in the initial abnormality stage

性故障,并且在后期出现的频率明显上升,表明故障从瞬时性向间歇性故障过渡。

如图9所示,传感器处于加速劣化阶段,特点是故障频率和强度显著增加,预测对比的偏差表明模型无法准确跟踪实际压力,并在300、500和700窗口点附近出现持续性的偏离。残差比率大幅超过阈值,形成连续超标区间,说明传感器已经连续出现严重的间歇性故障,并且

有往永久性故障过渡的趋势。

如图10所示,失效阶段压力传感器已发生永久性故障,仅在约300及700~800窗口附近短暂恢复正常输出,多为工况波动或噪声引起的假性修复。因硬件损伤不可逆,这些瞬时回升难以维持,系统很快回落为持续异常,侧面说明永久性故障的不可逆性,传感器仅能在极端偶然条件下瞬时输出正常值,但无法维持,最终持续处于失效状态。

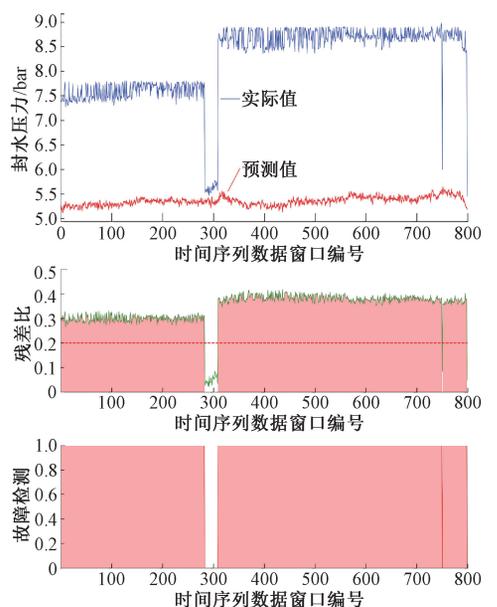


图10 失效阶段压力传感器故障诊断结果

Fig. 10 Fault diagnosis results of pressure sensor during failure stage

根据拟合得到的封水压力传感器可靠度曲线分析,关键节点的可靠度分别为 $\xi_1 = 0.995$, $\xi_2 = 0.798$, $\xi_3 = 0.581$, $\xi_4 = 0.087$, 如图 11 所示。该曲线由式 (15)~(21) 计算并拟合得到,系统性揭示了传感器从健康到失效的完整生命周期演化过程。初始阶段可靠度稳定保持在 0.99 以上,表明长期处于正常工作状态;进入初期异常后可靠度缓慢下降,虽出现零星故障但性能仍可接受;在加速劣化阶段可靠度快速跌至 0.798 再降至 0.581,说明故障频率和持续性显著增强,且退化不可逆;最终进入失效阶段,可靠度骤降至 0.087,表明传感器已难以维持功能。整体曲线充分反映性能随时间累积退化的客观规律,为健康状态评估提供可靠依据。

表 7 结果表明,压力传感器健康状态随时间呈递进式退化规律。健康阶段故障率极低 (0.000 15)、残差比接近 0,性能保持最优;初期异常阶段故障率升至 0.008 16,残差比明显放大,说明轻微异常已可被精准识别;加速劣化阶段故障率跃升至 0.032 62,残差快速累积,可靠性显著下降并呈加速趋势;进入失效阶段故障率

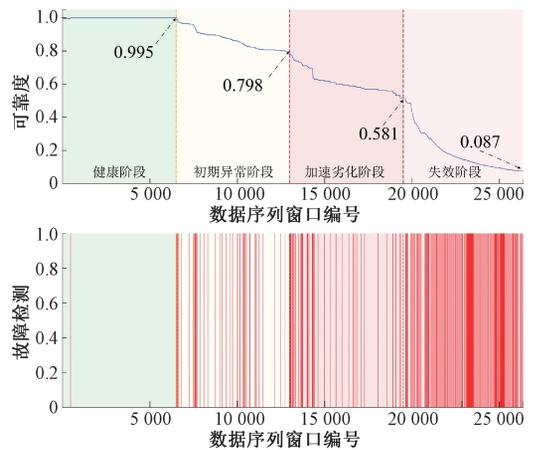


图 11 压力传感器可靠度下降曲线

Fig. 11 Reliability decline curve of pressure sensor

激增至 0.687 71,平均残差比较加速劣化阶段上升 508.6%,表明性能基本丧失且难以恢复。研究表明,故障率与残差比联合指标可有效识别退化拐点,为健康评估、剩余寿命预测与维护策略制定提供可靠依据。

表 7 各阶段故障诊断分析报告

Table 7 Fault diagnosis analysis report for each stage

阶段	故障检测次数	最大故障窗口	故障总窗口	故障率	平均残差比	最大残差比
健康阶段	1	1	1	0.000 15	0.018 60	0.227
初期异常阶段	52	2	53	0.008 16	0.037 49	1.180
加速劣化阶段	48	26	212	0.032 62	0.052 25	1.053
失效阶段	197	468	4 717	0.687 71	0.317 97	2.807

3.6 模型通用性分析

所提出的“物理机理-数据驱动融合”虚拟传感器构建方法由 MCNN-Transformer 结构、物理信息神经网络约束机制、物理-数据残差诊断策略以及可靠度评估模型协同构成。需要强调的是,该方法的理念并不依赖于具体传感器的类型、结构或内部机理,而是建立在疏浚装备中普遍存在的、可由物理规律描述的测控量与可连续采集的时序数据这一共性条件之上。只要目标测控单元具备可构建的物理表达式,并能够以时间序列形式采集运行状态,该虚拟传感器框架即可在不同对象之间实现直接迁移,为复杂工况下的跨装备应用提供通用化基础。

在物理模型层,PINN 所采用的物理分支可统一表示,如式 (37) 所示。

$$\hat{y}_{\text{phys}} = f_{\text{phys}}(u; \theta) \quad (37)$$

其中, u 为特征输入; θ 为可拟合物理参数。以封水压力为例,物理项由水力方程构建;对于其他测控单

元,如泵轴承温度、电机电流、液压压力等,可分别替换为热力学模型、能量平衡模型或流体动力学方程,以生成任务相关的物理预测项。由此可见,物理模块具有可解释、可扩展和可通用性,只需依据目标设备建立对应机理表达,即可完成模型横向迁移。PINN 所采用的混合损失结构在多任务间保持一致,因此无需更改网络主体,即可实现通用的物理-数据融合机制。

同时,所采用的残差诊断策略基于预测值与实测值之间的偏差构建,如式 (12) 和 (13) 所示,该判据不依赖量纲,可适用于压力、温度、电流、振动等多类型监测量。可靠度评估模型依据故障持续时间、发生频次及窗口统计特征建立,并可通过调整窗口与阈值设置扩展至不同测控对象。

综上,该方法在不改变整体框架的前提下,可迁移至疏浚装备多类关键测控单元,实现虚拟传感器构建、异常诊断与健康评估的一体化智能维护能力,为复杂工况下的跨装备健康管理提供通用化解决方案。

4 结 论

针对泥泵封水系统压力传感器在复杂非线性工况下易出现性能衰退、信号偏差及失效的问题,提出了一种兼具物理可解释性与工程适应性的泥泵封水系统压力传感器故障诊断与健康评估方法,实现了对复杂非线性工况下传感器全寿命性能退化的精准感知与量化表征。通过构建基于封水泵水力特性的封水压力物理模型,并引入动态系数提升模型对运行状态变化的适应性;基于MCNN-Transformer构建物理正则化PINN模型,初期依托物理约束快速收敛,后期通过数据误差主导优化提升拟合精度,从而实现解的物理一致性与数值精度的联合增强,并确定了最优权重配比。基于物理-数据预测与感知数据间残差构建故障诊断指标,准确识别异常的发生与消退过程,并同时捕捉瞬时性故障冲击和随机退化特征,揭示传感器退化并非单调稳定,而是呈现波动叠加的渐进演化规律。在此基础上提出的多参数可靠度计算框架,可独立量化传感器由健康阶段向早期退化、加速劣化直至功能失效的完整演化轨迹,其可靠度曲线清晰呈现“平缓—加速—骤降”的典型失效特征,为预测性维护提供可信的定量依据。实验结果验证,所构建的物理引导型PINN虚拟传感器在精度、收敛性与鲁棒性方面均显著优于传统纯数据驱动模型,且故障诊断模型能够实现封水压力传感器全寿命健康状态的持续跟踪与退化机理追溯,为疏浚装备关键测控单元的智能维护提供了有效技术路径。

参考文献

- [1] 范世东,袁俊朗,危卫,等. 绞吸式挖泥船吸扬系统性能提升及绿色智能化发展趋势[J]. 船海工程,2025,54(5):1-9,29.
FAN SH D, YUAN J L, WEI W, et al. Performance improvement and green intelligent development trend of cutter suction dredger suction-lifting system[J]. Ship & Ocean Engineering, 2025, 54(5):1-9,29.
- [2] 黄超,刘亚东,何炎平,等. 大型绞吸挖泥船泥泵封水系统设计[J]. 机电设备,2017,34(5):37-42.
HUANG CH, LIU Y D, HE Y P, et al. Gland water system design for dredge pump of large cutter suction dredger[J]. Mechanical and Electrical Equipment, 2017, 34(5): 37-42.
- [3] LONG ZH CH, FAN SH D, GAO Q, et al. Replacement

of fault sensor of cutter suction dredger mud pump based on MCNN Transformer [J]. Applied Sciences, 2024, 14(10): 4186.

- [4] 肖盈飞,刘海颖,程月华,等. 基于双模型自适应估计的大气数据传感器故障诊断方法[J]. 系统工程与电子技术,2024,46(11):3792-3799.
XIAO Y F, LIU H Y, CHENG Y H, et al. Fault diagnosis method for air data sensors based on dual-model adaptive estimation[J]. Systems Engineering and Electronics, 2024, 46(11): 3792-3799.
- [5] 王玉静,叶柏宏,康守强,等. 多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法[J]. 仪器仪表学报,2025,46(6):317-329.
WANG Y J, YE B H, KANG SH Q, et al. Fault diagnosis method for harmonic reducers based on federated learning with multi-source imbalanced data[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 317-329.
- [6] 郁明,李旺林,蓝盾. 基于优化自适应阈值的非线性机电系统传感器故障检测和主动容错控制[J]. 仪器仪表学报,2022,43(4):26-37.
YU M, LI W L, LAN D. Sensor fault detection and active fault-tolerant control for nonlinear mechatronic systems based on optimized adaptive threshold[J]. Chinese Journal of Scientific Instrument, 2022, 43(4): 26-37.
- [7] GAO SH, WANG Y, ZHANG ZH Y, et al. Hybrid fault diagnosis method for underwater thrusters based on the common features of multi-source signals[J]. Mechanical Systems and Signal Processing, 2025, 222: 111740.
- [8] 孙源,陈杰,卫梦龙,等. 非线性负载下的三相逆变器开路 and 电流传感器同时故障的诊断[J]. 仪器仪表学报,2024,45(11):52-64.
SUN Y, CHEN J, WEI M L, et al. Simultaneous faults diagnosis of three-phase inverter open-circuits and current sensors under nonlinear load [J]. Chinese Journal of Scientific Instrument, 2024, 45(11): 52-64.
- [9] 汪少华,时玉鹏,施德华,等. 多模机电复合传动系统多传感器故障自适应诊断策略[J/OL]. 吉林大学学报(工学版),1-12[2025-11-25].
WANG SH H, SHI Y P, SHI D H, et al. Adaptive diagnosis strategy of multi-sensors fault for multi-mode

- electromechanical compound drive systems[J/OL]. Journal of Jilin University (Engineering and Technology Edition), 1-12[2025-11-25].
- [10] 许水清,许晓凡,何怡刚,等. 基于自适应滑模观测器的中点钳位型三电平并网逆变器开关管和电流传感器故障诊断[J]. 电工技术学报,2024,39(13):4066-4078.
XU SH Q, XU X F, HE Y G, et al. Fault diagnosis of neutral point clamped three-level grid-connected inverter based on adaptive sliding mode observer[J]. Transactions of China Electrotechnical Society, 2024, 39(13): 4066-4078.
- [11] HUANG T L, PAN H H, SUN W CH. A sensor fault detection, isolation, and estimation method for intelligent vehicles[J]. Control Engineering Practice, 2023, 139: 105620.
- [12] AHMAD M, AZEEM F, ZIDAN H A. Robust residual generator design for sensor fault detection in twin rotor aerodynamic system[J]. e-Prime-Advances in Electrical Engineering, Electronics and Energy, 2024, 8: 100620.
- [13] TARIQ S, LOY-BENITEZ J, YOO C. Multi-sensor fault detection and correction for automated IAQ monitoring in smart buildings through attention-aware autoencoders with spatial prediction module[J]. Journal of Building Engineering, 2024, 96: 110573.
- [14] 江灏,叶铭新,林蔚青,等. 基于时空动态检测的核电厂堆外中子探测器故障检测方法[J]. 仪器仪表学报,2024,45(9):131-144.
JIANG H, YE M X, LIN W Q, et al. Fault detection for ex-core neutron detectors in nuclear power plants using spatial-temporal dynamic detection model[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 131-144.
- [15] GUO J CH, HE Q B, ZHEN D, et al. Multi-sensor data fusion for rotating machinery fault detection using improved cyclic spectral covariance matrix and motor current signal analysis[J]. Reliability Engineering & System Safety, 2023, 230: 108969.
- [16] JAN S U, LEE Y D, KOO I S. A distributed sensor-fault detection and diagnosis framework using machine learning[J]. Information Sciences, 2021, 547: 777-796.
- [17] WU P G, HU Y P, LI G N, et al. Sensor fault detection, diagnosis, and data reconstruction strategy for chiller based on an improved tree-based pipeline optimization tool framework[J]. International Journal of Refrigeration, 2025, 174: 60-75.
- [18] MOHAPATRA D, SUBUDHI B, DANIEL R. Real-time sensor fault detection in Tokamak using different machine learning algorithms[J]. Fusion Engineering and Design, 2020, 151: 111401.
- [19] JIHANI N, KABBAJ M N, BENBRAHIM M. Kalman filter based sensor fault detection in wireless sensor network for smart irrigation[J]. Results in Engineering, 2023, 20: 101395.
- [20] WEN L, LI X Y, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50[J]. Neural Computing and Applications, 2020, 32(10): 6111-6124.
- [21] 蒋栋年,褚天锐,高玉鑫. 基于冗余关系分析的传感器自诊断设计方法研究[J]. 仪器仪表学报, 2024, 45(3): 72-83.
JIANG D N, CHU T R, GAO Y X. Research on sensor self-diagnosis design method based on redundancy relationship analysis[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 72-83.
- [22] HOSSEINI LAVASSANI S H, DOROUDI R, SHAHROUZI M, et al. A comprehensive method for sensor fault detection and signal reconstruction in structural health monitoring systems for super-tall buildings[J]. Structures, 2025, 75: 108866.
- [23] 熊伟,苟斌,张坤,等. 基于数据驱动的牵引逆变器电压传感器间歇性故障诊断方法[J]. 中国电机工程学报, 2024, 44(11): 4446-4459.
XIONG W, GOU B, ZHANG K, et al. A data-driven method for voltage sensor intermittent faults of traction inverter system[J]. Proceedings of the CSEE, 2024, 44(11): 4446-4459.
- [24] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440.
- [25] 余旭涛,吴威,牛刚. 磁浮列车双冗余加速度传感器故障检测研究[J]. 仪器仪表学报,2023,44(10):138-144.
YU X T, WU W, NIU G. Research on fault detection of

double redundant acceleration sensor for maglev train[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 138-144.

- [26] 米洁, 马超, 周海龙, 等. 物理知识引导的卷积神经网络故障诊断预测方法[J]. 仪器仪表学报, 2025, 46(8): 19-32.

MI J, MA CH, ZHOU H L, et al. Physical-guided convolutional neural network method for fault diagnosis[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 19-32.

作者简介



龙哲诚, 2020 年于长春工程学院获得学士学位, 2021 年于利兹大学获得硕士学位, 现于武汉理工大学攻读博士学位, 主要研究方向为设备可靠性提升及故障诊断。

E-mail: zelong@whut.edu.cn

Long Zhecheng received his B.Sc. degree from Changchun Institute of Technology in 2020, and his M.Sc. degree from the University of Leeds in 2021. He is currently pursuing his Ph.D. degree at Wuhan University of Technology. His main research interests include equipment reliability enhancement and fault diagnosis.



张鹏, 2011 年毕业于武汉大学获得学士学位, 现为中交广航疏浚有限公司技术中心主任, 主要研究方向为港口航道与海岸工程。

E-mail: 2105878151@qq.com

Zhang Peng received his B.Sc. degree from Wuhan University in 2011. He is currently a director of the Technology Center at CCCG Guangzhou Dredging Co., Ltd. His main research interests include port, channel and coastal engineering.



范世东(通信作者), 1984 年于武汉水运工程学院获得学士学位, 1990 年于武汉水运工程学院获得硕士学位, 1996 年于大连海事大学获得博士学位, 现为武汉理工大学教授, 主要研究方法为设备可靠性及运维保障。

E-mail: sdfan@whut.edu.cn

Fan Shidong (Corresponding author) received his B.Sc. and M.Sc. degrees both from Wuhan River Transportation University in 1984 and 1990, respectively, and his Ph.D. degree from Dalian Maritime University in 1996. He is currently a professor at Wuhan University of Technology. His main research interests include equipment reliability and operation and maintenance support.