

DOI: 10.13382/j.jemi.B2206028

# 模糊推理和深度学习数模融合的 卡尔曼滤波腐蚀预测\*

尹爱军 朱文浩 戴宗贤 任宏基

(1. 重庆大学机械与运载工程学院 重庆 400044; 2. 重庆市计量质量检测研究院 重庆 401120;

3. 重庆电子工程职业学院 重庆 401331)

**摘要:** 腐蚀状态的准确预测对油气储运、化工设备安全可靠运行具有重要意义。因腐蚀过程复杂,影响因素多,导致常规腐蚀预测方法中先验模型对环境依赖性大,中长期预测效果差。本文提出一种融合模糊推理和深度学习的数模融合驱动的卡尔曼滤波腐蚀预测方法。首先结合腐蚀物理模型和实际监测数据,建立腐蚀速度模糊规则,得到基于现场环境的结合物理模型的修正腐蚀速度。同时针对模糊推理结果存在的预测滞后性,考虑腐蚀监测数据的长期规律性,利用深度学习预测腐蚀速度;然后融合模糊策略和深度学习预测结果,实现基于卡尔曼滤波的数模融合腐蚀预测。最后利用天然气管道实际腐蚀监测数据,与高斯过程回归(Gaussian process regression, GPR),粒子群优化灰度模型(particle swarm optimization gray model, PSO GM),模糊推理(fuzzy reasoning, FR),多层感知机(multilayer perceptron, MLP)和卡尔曼滤波预测方法(Kalman filter, KF)进行了对比验证分析。结果表明本文所提方法具有良好的预测效果,对两年内腐蚀状态的相对预测误差在1%范围内,均方根误差为0.000 49 mm,平均绝对百分比误差为0.34%。

**关键词:** 模糊推理;深度学习;卡尔曼滤波;数模融合;管道腐蚀;时序预测

中图分类号: TP183;TE319

文献标识码: A

国家标准学科分类代码: 510.4

## Kalman filter corrosion prediction based on data and physical model fusion driven using fuzzy reasoning and deep learning

Yin Aijun Zhu Wenhao Dai Zongxian Ren Hongji

(1. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China;

2. Chongqing Institute of Measurement and Quality Inspection, Chongqing 401120, China;

3. Chongqing Electronic Engineering Vocational College, Chongqing 401331, China)

**Abstract:** Accurate prediction of corrosion state is very important for storage and transportation of oil and gas and safe and reliable operation of chemical equipment. Due to the complex corrosion process and many influencing factors, the prior model in the conventional corrosion prediction method is highly dependent on the environment and the medium and long-term prediction effect is poor. In this paper, a digital analog fusion driven Kalman filter corrosion prediction method integrating fuzzy reasoning and deep learning is proposed. Firstly, based on the long-term corrosion physical model and the actual short-term monitoring data, the fuzzy rules of corrosion velocity were established to obtain the modified corrosion velocity based on the field environment. At the same time, aiming at the prediction lag of fuzzy reasoning results and considering the long-term regularity of corrosion monitoring data, deep learning is used to predict the corrosion rate. Then, the fuzzy strategy and deep learning prediction results are fused to realize the digital analog fusion corrosion prediction based on Kalman filter. Finally, using the actual corrosion monitoring data of natural gas pipelines, this prediction method is compared with GPR, GM, PSO GM, FR, MLP and Kalman filter. The results show that the proposed method has good prediction effect. The relative prediction error of corrosion state in two years is within 1%, the root mean square error is 0.000 49 mm, and the average absolute percentage error is 0.34%.

**Keywords:** fuzzy reasoning; deep learning; Kalman filter; digital analog fusion; pipeline corrosion; time series prediction

收稿日期: 2022-11-21 Received Date: 2022-11-21

\* 基金项目: 国家自然科学基金(52275518)、国家重点研发计划(2020YFB1709800)项目资助

## 0 引言

管道服役过程中随着流体冲刷、电化学腐蚀、化学腐蚀等不断作用,使管壁逐步产生壁减薄、腐蚀、裂纹等缺陷<sup>[1-2]</sup>。一旦腐蚀量过大,将导致泄漏等事故,对自然环境、企业效益和社会安全造成重大影响。因此对管道腐蚀状态进行实时监测与预测对管道健康状态控制与管理决策至关重要。

何天隆等<sup>[3]</sup>基于新型灰色模型(grey model, GM)预测油气管道腐蚀速率,提升了腐蚀预测精度。Chen等<sup>[4]</sup>利用主成分分析法(principal component analysis, PCA)提取管道腐蚀的高贡献影响因素,以评估海底管道失效原因。Jian等<sup>[5]</sup>建立粒子群优化(particle swarm optimization, PSO)与支持向量机(support vector machines, SVM)模型对管道内部和外部腐蚀状况进行识别与分类。李瑞莲等<sup>[6]</sup>基于数据驱动建立回归模型,通过逐步回归取得了对金属供水管网腐蚀状况较好的预测效果。李丽等<sup>[7]</sup>基于神经网络构建了碳钢年土壤腐蚀模型,较好地预测了我国典型地区碳钢在土壤中的腐蚀速率。由于腐蚀过程影响因素较多,而常规腐蚀预测方法需要综合考虑腐蚀发生环境,如PH值、二氧化碳分压、含氧量等影响因素,导致泛化能力较弱,实施较困难。由于基于时间序列的预测方法弱化了过程影响因素,在工程上具有更好的泛化能力,所以得到相关研究,并广泛应用于生态、医疗和金融等领域。但基于时序的预测方法缺少对物理过程的深入探索,使其在机械寿命预测,尤其是管道腐蚀预测方面应用较少。段俊峰等<sup>[8]</sup>结合现场环境,利用高斯过程回归预测智能电表剩余寿命。陈佳鲜等<sup>[9]</sup>构建轴承时间序列迁移递归预测模型,利用深度迁移学习在线预测滚动轴承剩余寿命。

本文结合腐蚀物理模型和实际监测数据,提出融合模糊推理和深度学习的腐蚀预测方法。首先针对环境、传感器等因素导致的监测数据可能存在的不合理性,结合腐蚀物理模型,建立模糊规则;同时针对模糊推理存在的滞后性,并考虑长期监测数据的规律,建立深度学习预测模型;最后融合模糊推理和深度学习的结果,利用卡尔曼滤波方法(KF),建立腐蚀预测模型,提高预测的准确性和鲁棒性。

## 1 基本理论方法

### 1.1 腐蚀物理模型

根据腐蚀深度随时间变化规律,管道腐蚀模型主要有线性模型、幂模型、指数模型3种<sup>[10]</sup>。

腐蚀线性模型是对腐蚀时变信号的最简化模型

如下:

$$d = v_d t \quad (1)$$

式中: $d$ 为腐蚀深度; $t$ 为腐蚀时间; $v_d$ 为标定腐蚀速率。

线性模型应用简单,主要用于稳态腐蚀过程<sup>[9]</sup>,但由于其忽略腐蚀速率随时间的变化,模型包含信息过少。

腐蚀指数模型认为腐蚀剩余管道壁厚与腐蚀时间呈指数关系:

$$d = d_0 - G e^{h(t-T_0)} \quad (2)$$

式中: $d_0$ 管道初始厚度; $T_0$ 腐蚀开始时间; $G$ 、 $h$ 为待定系数。

指数模型考虑了管道腐蚀产物附着在管道表面,进而对腐蚀的产生抑制作用。但腐蚀产物对管道的保护作用大小暂无判定,导致其有效性有待商榷。

幂模型是目前工程上应用最广泛的模型<sup>[11-12]</sup>:

$$d = k(t - T_0)^a \quad (3)$$

式中: $k$ 、 $a$ 为待定系数。

幂模型中当 $a=1$ 时,为线性模型;当 $a<1$ 时,同样考虑随着腐蚀时间增加,氧气通过锈层到金属表面速率下降,导致腐蚀减缓的情况。比起另外两个模型,具有灵活合理特点,且更加安全。

### 1.2 卡尔曼滤波

卡尔曼滤波器是一个最优化自回归数据处理算法<sup>[13]</sup>。方法综合考虑观测量和预测量,具有良好的实时性、智能性和精确性。其基本思想为利用前一时刻状态,根据状态空间模型,得到当前时刻估计值,并结合当前时刻观测量更新对当前状态的估计,从而得到满足最小均方差的当前状态变量<sup>[14]</sup>。根据不同目标,可用于参数估计、预测等任务。

将系统动态空间描述为:

$$\begin{cases} \hat{\mathbf{x}}_t^- = \mathbf{F}\hat{\mathbf{x}}_{t-1}^- + \mathbf{B}\mathbf{u}_{t-1} \\ \mathbf{Z}_t = \mathbf{H}\hat{\mathbf{x}}_t^- + \boldsymbol{\gamma} \end{cases} \quad (4)$$

其卡尔曼滤波状态更新方程为:

$$\begin{cases} \mathbf{P}_t^- = \mathbf{F}\mathbf{P}_{t-1}^- \mathbf{F}^T + \mathbf{Q} \\ \mathbf{K}_t = \frac{\mathbf{P}_t^- \mathbf{H}^T}{\mathbf{H}\mathbf{P}_t^- \mathbf{H}^T + \mathbf{R}} \\ \mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}) \mathbf{P}_t^- \end{cases} \quad (5)$$

结合动态空间方程预测结果:

$$\hat{\mathbf{x}}_t = \hat{\mathbf{x}}_t^- + \mathbf{K}_t (\mathbf{Z}_t - \mathbf{H}\hat{\mathbf{x}}_t^-) \quad (6)$$

其中, $\hat{\mathbf{x}}_t^-$ 表示当前时刻预测量; $\hat{\mathbf{x}}_{t-1}^-$ 表示上时刻状态量; $\mathbf{F}$ 表示系统状态矩阵; $\mathbf{B}$ 为干扰输入矩阵; $\mathbf{Z}_t$ 表示观测量; $\mathbf{H}$ 表示观测转移矩阵; $\hat{\mathbf{x}}_t$ 表示当前时刻状态量; $\boldsymbol{\gamma}$ 和 $\mathbf{u}_{t-1}$ 为高斯白噪声; $\mathbf{K}_t$ 表示状态更新矩阵; $\mathbf{P}_t^-$ 表示状态协方差; $\mathbf{P}_{t-1}^-$ 表示上一时刻状态协方差; $\mathbf{P}_t$ 表示更新协方差; $\mathbf{Q}$ 、 $\mathbf{R}$ 表示预测误差与观测误差的超参量; $\mathbf{I}$ 表

示单位矩阵;系统状态矩阵包含的主要信息为腐蚀深度和腐蚀速度,且  $F, H$  的取值由腐蚀模型确定。

然而实际中,由于湿度、温度、流量、昼夜温差甚至管道振动等会影响液膜厚度、固体颗粒吸附程度、酸性气体溶解度和化学反应速率等<sup>[15]</sup>,使得腐蚀的演化过程更为复杂,难以建立准确的映射关系,特别是随着预测时间尺度的延长,模型准确度进一步下降。由于物理模型的不确定,且缺乏参考与反馈,因此直接利用卡尔曼滤波进行腐蚀预测准确性差。

## 2 融合模糊推理和深度学习的腐蚀预测

针对腐蚀物理模型不精确和数据利用不充分的问题,本文通过模糊推理解决腐蚀物理过程环境适应性和合理性问题,通过深度学习解决预测滞后和数据本身的规律性问题,然后融合两种预测结果建立基于卡尔曼滤波的数模融合腐蚀预测模型,下文简称 FD-KF (fuzzy inference and deep learning for Kalman filter)。

### 2.1 腐蚀速度模糊推理

模糊推理是边界不分明的智能推理方法,广泛应用于故障诊断等领域中<sup>[16]</sup>,主要包括输入量模糊化、模糊规则、模糊推理和解模糊化<sup>[17]</sup>。模糊推理方法是模糊推理的核心,常用的模糊推理方法包括 Zadeh 的 CRI 方法、全蕴涵三 I 算法、Mamdani 算法、Dubois-Prade 算法、陈永义的特征展开方法等<sup>[18]</sup>。解模糊化运算将推理模糊值转换为明确输出信号,常用方法包括最大隶属度法,重心法和加权平均法等。

根据式 (3),利用长期监测数据  $D_l$  求解最小二乘建立腐蚀过程幂模型,求导后得到反映长期变化趋势的腐蚀速度  $V_l$  :

$$V_l = ak(T_i - T_0)^{a-1} \quad (7)$$

式中:  $T_i$  为归一化时间参数。

$V_l$  反应管道内电化学腐蚀物理变化趋势,具有较强的物理意义,但对现场短期的突发状况缺少修订,如气温骤降等反常天气的缺少及时的反馈,导致其预测精度随时间的变化不断降低。考虑到腐蚀是一个缓慢变化的过程,短期内可以近似为线性过程,因此利用短期监测数据  $D_s$ ,根据式 (8),通过线性回归方法得到的近期腐蚀速度  $V_s$  :

$$V_s = \frac{\sum_{i=1}^n (d_i - \bar{d})(T_i - \bar{T})}{\sum_{i=1}^n (d_i - \bar{d})^2} \quad (8)$$

其中,  $d_i$  为观测腐蚀深度;  $\bar{d}, \bar{T}$  为观测深度与时间平均值。

相比反映长期趋势的物理模型,近期预测模型由于

更小的时间尺度,能更直接地体现腐蚀现场环境变化,准确性更高,但由于短期监测数据量和变化量较小,且由于野外恶劣环境导致的较大的监测仪器随机误差,短期预测速度可能会出现违反物理规律的情况,如预测腐蚀速度为负值等。因此以短期预测速度  $V_s$  与长期预测速度  $V_l$  的差值  $E$  和  $E$  的导数  $EC$  为模糊推理的输入量,腐蚀速度  $V_{pt}$  为输出量。

本文采用 Mamdani 型推理算法对  $E$  和  $EC$  进行运算,采用最大隶属度法对推理结果解模糊化,其过程如图 1 所示。

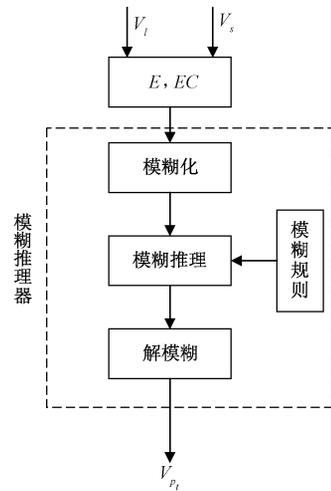


图 1 腐蚀速度模糊推理过程

Fig. 1 Fuzzy inference process of corrosion rate

根据工程经验与实验分析,将  $E$  分为 5 个语言变量,分别为负大 NB ( $-\infty, -0.75V_l$ ),负小 NS ( $-1.25V_l, -0.25V_l$ ),零 Z ( $-0.75V_l, 0.75V_l$ ),正小 PS ( $0.25V_l, 1.25V_l$ ),正大 PB ( $0.75V_l, \infty$ );  $EC$  采用 2 个语言变量,分别为负 N ( $-\infty, 0$ ),正 P ( $0, \infty$ )。采用梯形隶属度函数确定  $E$  的模糊子集 NB,Z,PB,采用三角形隶属度函数确定 NS,PS;采用梯形隶属度函数确定  $EC$  的模糊子集 N,P;如图 2 和 3 所示。

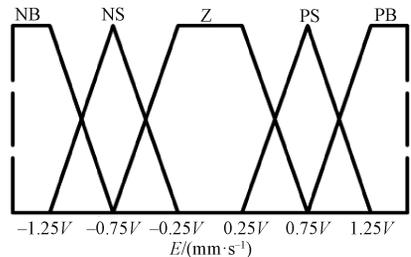


图 2 E 隶属度分布

Fig. 2 E membership distribution

基于短期预测  $V_s$  与长期预测  $V_l$  的相合度,制定模糊

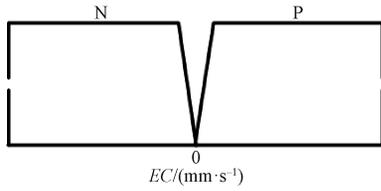


图 3 EC 隶属度分布

Fig. 3 EC membership distribution

规则,结合腐蚀速度物理模型,得到符合实际的腐蚀速度变化。模糊规则调整策略如下:

- 1) 当短期腐蚀速度  $V_s$  与长期腐蚀速度  $V_l$  相差较大时,更信任  $V_s$ ;
- 2) 当短期腐蚀速度  $V_s$  与长期腐蚀速度  $V_l$  相差不大时,对两者信任程度相近;
- 3) 当短期腐蚀速度  $V_s$  小于 0 时,更信任长期腐蚀速度  $V_l$ ;
- 4) 当前短期腐蚀速度大于上一次短期腐蚀速度时,  $V_s$  更可信。

依据上述策略,得到 10 条模糊逻辑规则,如表 1 所示。表中数字表示对短期腐蚀速度的信任程度  $\alpha$ 。

表 1 模糊规则  
Table 1 Fuzzy rules

	NB	NS	Z	PS	PB
P	NM(0.1)	PS(0.8)	Z(0.6)	PS(0.8)	PB(1)
N	NB(0)	NS(0.7)	Z(0.5)	NS(0.7)	PM(0.9)

于是,结合反映物理模型的长期腐蚀速度  $V_l$  和短期腐蚀速度  $V_s$ ,得到如式(9)所示模糊推理腐蚀速度  $V_{p_i}$ 。

$$V_{p_i} = \alpha V_s + (1 - \alpha) V_l \quad (9)$$

### 2.2 基于深度学习的腐蚀速度预测

模糊推理速度  $V_{p_i}$  虽然尽可能接近近期真实腐蚀速度,但其推理过程对近期少量数据依赖较大,导致其预测结果难以反映腐蚀长期趋势。虽然腐蚀是一个缓慢变化的过程,但季节性等因素会导致腐蚀速度长周期性的变化,因此本文结合长期历史数据,利用深度学习<sup>[19-20]</sup>预测未来一段时间内的腐蚀速度,以减小结果的滞后性,进一步提高腐蚀预测能力。

因为基于腐蚀模型的长期腐蚀速度  $V_l$  反映了腐蚀演化过程的时间进程,短期腐蚀速度  $V_s$  反映了腐蚀环境等信息,腐蚀深度  $d_i$  反映当前信息,因此将  $V_s$ 、 $V_l$  和  $d_i$  作为输入量,  $V_{M_i}$  作为腐蚀速度的预测输出量,建立腐蚀预测的全连接 BP 深度神经网络,架构如图 4 所

示。其中深度学习网络为 4 层网络,包含 1 个 3 结点的输入层 I,1 个单结点输出层 O,2 个 4 个神经元结点隐含层 H1、H2;激活函数采用 tanh 函数;采用均方损失函数;学习率为 0.1。此神经网络结构采用 MLP,增加数据的非线性映射能力,同时通过梯度下降的回归预测方法,将输出误差反向传播,分摊到神经网络各层所有结点和单元。

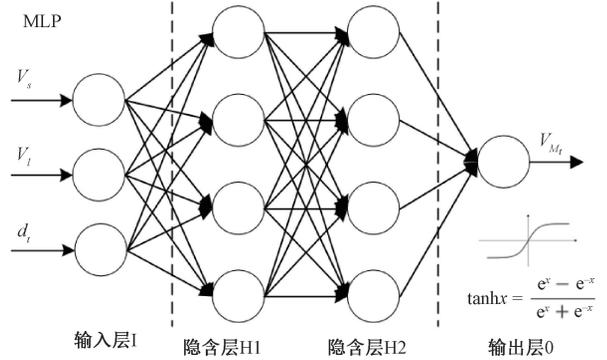


图 4 MLP 层次架构图

Fig. 4 MLP hierarchical architecture diagram

### 2.3 数模融合驱动的 FD-KF 腐蚀预测

模糊推理考虑到了环境适应性,其更能反应腐蚀现场的变化过程,但其具有延时性;深度学习网络挖掘数据规律,获取腐蚀预测模型,补偿模糊推理延时,但对弱规律系统建模预测精度不高。为提高方法的准确性与鲁棒性,建立如式(10)所示的腐蚀速度预测融合机制。

$$V_i = \frac{\Delta P_{i-1}}{\Delta P_{i-1} + \Delta M_{i-1}} V_{M_i} + \frac{\Delta M_{i-1}}{\Delta P_{i-1} + \Delta M_{i-1}} V_{p_i} \quad (10)$$

其中:

$$\Delta P_{i-1} = V_s - V_{p_{i-1}} \quad (11)$$

$$\Delta M_{i-1} = V_s - V_{M_{i-1}} \quad (12)$$

式中:  $\Delta P_{i-1}$  为模糊推理预测偏差,  $\Delta M_{i-1}$  为深度学习预测偏差,  $V_i$  为融合预测腐蚀速度。

最后以  $d_i$  和  $V_i$  为卡尔曼滤波的输入,根据式(4)、(6),得到卡尔曼滤波腐蚀预测模型:

$$\begin{bmatrix} d_{i+1}^* \\ V_i \end{bmatrix} = \begin{bmatrix} d_{i+1}^- \\ V_i \end{bmatrix} + \mathbf{K} \begin{bmatrix} d_{i+1} - d_{i+1}^- \\ 0 \end{bmatrix} \quad (13)$$

其中:

$$d_{i+1}^- = d_i^* + V_i \Delta t \quad (14)$$

$$d_{i+1} = d_i + V_i \Delta t \quad (15)$$

式中:  $d_{i+1}^*$  为卡尔曼滤波预测结果,  $d_i^*$  为上一次预测结果,  $d_{i+1}^-$  为隐空间估计值,  $d_{i+1}$  为观测空间估计值,  $\mathbf{K}$  为状态更新矩阵,  $\Delta t$  为腐蚀监测计量间隔。其流程如图 5 所示,算法过程如算法 1 所示。

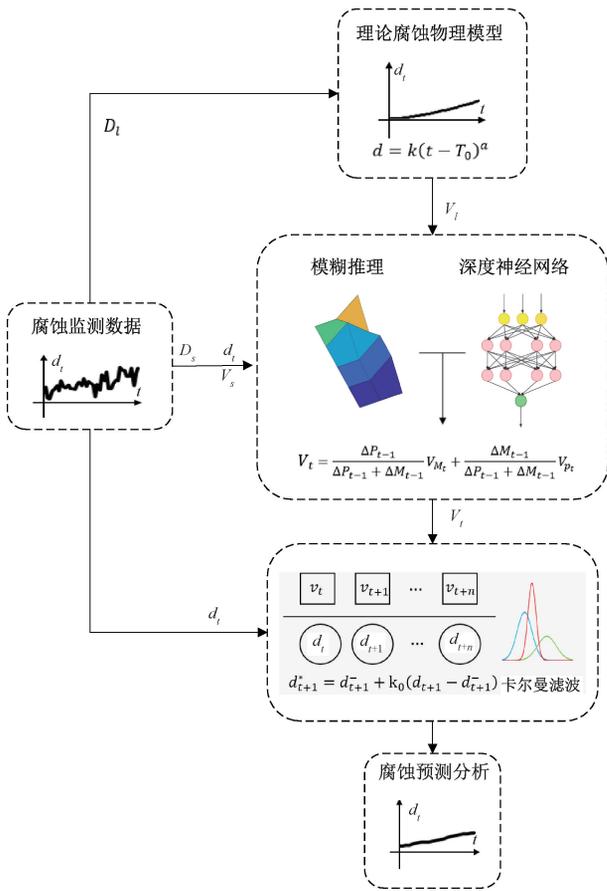


图5 FD-KF 腐蚀预测流程

Fig. 5 FD-KF corrosion prediction process

算法1:FD-KF 腐蚀预测算法

输入:近期腐蚀数据  $D_s$  (包含  $N_s$  个样本),  $\{(d_{i-n})\} | d_{i-n}, n = 0, \dots, N_s - 1$

输出:腐蚀预测结果  $\{(d_{i+1}^*)\} | \{d_{i+1}^* \in R\}$  ;

算法流程:

阶段1:模型训练阶段

- 1) 根据长期腐蚀数据  $D_l$ , 建立长期腐蚀过程物理幂模型, 计算  $V_l$
- 2) 从  $D_l$  中截取短期腐蚀数据  $D_s$ , 计算  $V_s$
- 3) 建立以  $V_l, V_s, d_i$  为输入,  $V_{M_t}$  为输出的深度学习模型并训练

阶段2:在线预测阶段

- 1) 根据近期腐蚀数据  $D_s$ , 计算短期腐蚀速度  $V_s$
- 2) 根据  $V_s, V_l$ , 模糊推理腐蚀速度  $V_{P_t}$
- 3) 根据  $V_l, V_s, d_i$ , 深度学习得到腐蚀速度  $V_{M_t}$
- 4) 根据式(10), 得到融合腐蚀速度  $V_i$
- 5) 根据式(13), 得到  $d_{i+1}^*$

### 3 实例分析

#### 3.1 数据来源

本文利用中石油重庆某天然气增压站管线的腐蚀监测数据进行验证对比分析。该管线分为 AB 两段, 起于云安 24 井, 止于万州末站, 全长 22.7 km, 采用 MS3510

腐蚀监测仪在线监测管道腐蚀情况, 如图 6 所示。监测仪共采集从 2012 年 2 月~2019 年 9 月间管道内腐蚀监测数据。



图6 天然气管道腐蚀监测现场

Fig. 6 Corrosion monitoring site of natural gas pipeline

将 92 个月的腐蚀数据通过 3 种腐蚀物理模型拟合, 如图 7 所示。通过决定系数  $R^2$  评估模型拟合效果, 对比分析可知幂模型的决定系数为 0.995 7, 相较于线性模型的 0.989 9 和指数模型的 0.995 3, 评估效果最好, 使用幂模型作为腐蚀的物理模型。

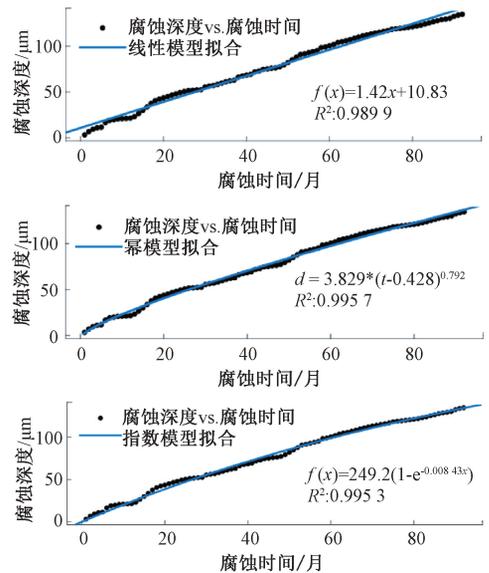


图7 腐蚀长期监测数据物理模型

Fig. 7 Physical model of long-term corrosion monitoring data

#### 3.2 $D_s$ 对预测性能的影响

将 2012 年 2 月~2017 年 9 月的腐蚀监测数据作为长期腐蚀数据  $D_l$ , 建立深度学习和腐蚀物理模型, 预测 2017 年 10 月~2019 年 9 月的腐蚀监测情况。由于短期腐蚀数据  $D_s$  的选择影响腐蚀预测效果, 分别取每隔 1 个月、2 个月和 3 个月的监测数据为  $D_s$ , 进行算法更新, 每个月进行一次预测, 结果如图 8 所示。由图可以看出, 不同  $D_s$  均能取得良好的预测效果。

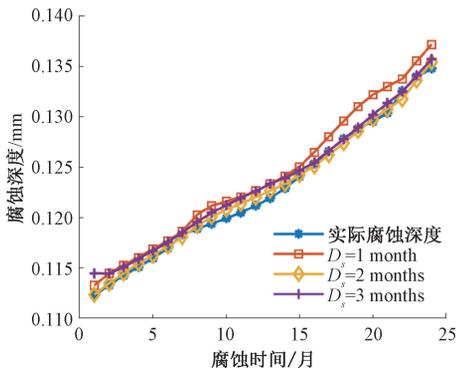


图 8 不同  $D_s$  腐蚀预测效果对比

Fig. 8 Comparison of corrosion prediction effects of different  $D_s$

图 9 反映了不同  $D_s$  的相对误差对比。总体上,其相对误差呈现相似的变化趋势。当  $D_s$  为 2 个月时,取得最好的预测效果,其最大相对误差为 0.738%;且两年内各时段相对误差均最小。其原因为  $D_s$  为一个月时短期数据量过少,而不能得到合理预测;  $D_s$  为 3 个月时短期趋势向长期演化,导致短期规律被掩盖;而  $D_s$  为两个月时,其数据量能更好地反映短期变化趋势,并提高预测精度。

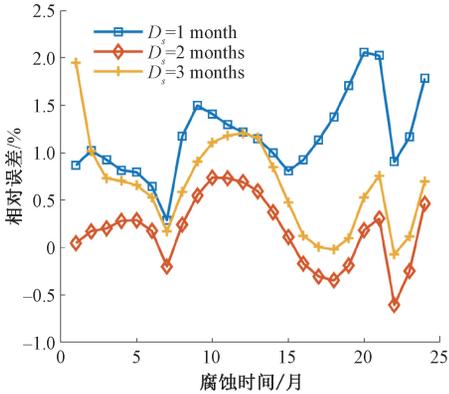


图 9 不同  $D_s$  预测误差对比

Fig. 9 Comparison of prediction errors of different  $D_s$

### 3.3 对比分析

本文分别采用 GPR、PSOGM、KF、FR、MLP 和 FD-KF 进行预测效果对比分析,如图 10 所示。各方法对腐蚀深度的预测均随时间而增大,均能正确反映腐蚀变化规律。

误差如图 11 所示。由图可以看出,GPR、PSOGM、MLP 和 KF 方法在预测初始阶段有最小的相对误差,但随着时间尺度的延长,预测误差总体呈逐渐增大趋势。FR 相对误差比较稳定,保持在 -5% 左右。PSOGM 方法具有更大的变化率,其相对误差先减小后增大,且在第 12 个月处达到最小相对误差。FD-KF 最大相对误差为 0.738%,最小相对误差为 0.108%,均小于其他方法;且 FD-KF 方法第 1 个月的预测误差为 0.047%,第 24 个月

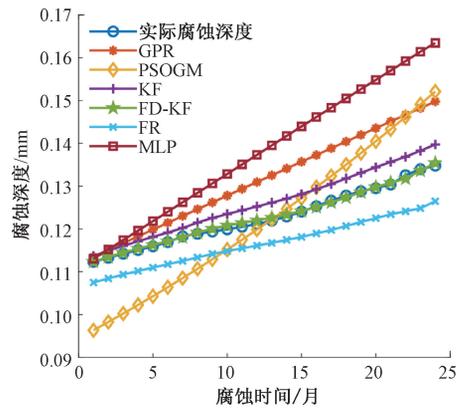


图 10 各方法预测效果对比

Fig. 10 Comparison of prediction effects of various methods

预测误差为 0.046 5%。FD-KF 的预测误差几乎不随时间延长而增大,具有良好的长期稳定性和准确性。

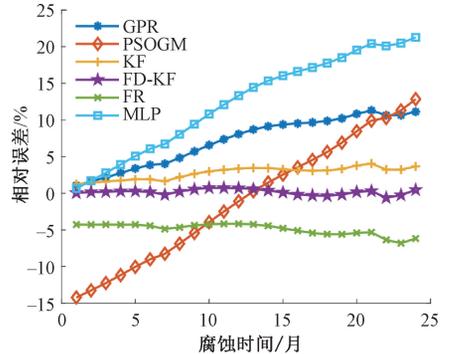


图 11 各方法预测误差对比

Fig. 11 Comparison of prediction errors of various methods

通过均方根误差  $E_{RMSE}$  进一步评估本文所提方法的稳定性,通过平均绝对百分比误差  $E_{MAPE}$  进一步评估本文所提方法的预测精度,如表 2 所示。分析可知 FD-KF 的  $E_{RMSE}$  和  $E_{MAPE}$  分别为 0.000 49 和 0.34%,均小于其他方法。相对于 GPR、PSOGM、FR、MLP 与 KF,本文所提方法在  $E_{RMSE}$  指标上分别降低 0.009 58 mm、0.097 6 mm、0.005 5 mm、0.016 48 mm 和 0.003 14 mm;在  $E_{MAPE}$  指标上分别降低 6.85%、6.98%、4.38%、11.19% 和 2.44%。表明本文所提方法在具有更高的预测性能。

表 2 预测偏差评价

Table 2 Prediction deviation evaluation

方法	$E_{RMSE}/mm$	$E_{MAPE}/%$
GPR	0.010 07	7.19
PSOGM	0.010 25	7.32
KF	0.003 63	2.78
FR	0.005 99	4.72
MLP	0.016 97	11.53
FD-KF	0.000 49	0.34

## 4 结 论

针对腐蚀监测过程中,腐蚀预测影响因素多,预测偏差较大的问题,本文融合模糊推理和深度学习,建立了基于卡尔曼滤波的数模融合腐蚀预测方法。方法采用模糊推理解决腐蚀现场环境复杂多变性和短期预测不合理性的问题;采用深度学习补偿模糊推理的腐蚀预测状态滞后,并建立长期预测关系;融合二者的预测结果,建立数模融合的卡尔曼滤波预测模型,提升了方法的鲁棒性与准确性,克服了卡尔曼滤波对弱规律系统的预测效果差的缺陷。实际验证对比结果表明,本文方法相对误差小于1%,长期预测误差小,评估稳定可靠,证明了方法的可行性与有效性。

## 参考文献

- [ 1 ] 张宝,王仕强,彭建云,等. 在役高压井口装置检测技术应用[J]. 北京石油化工学院学报,2018,26(4):43-47.  
ZHANG B, WANG SH Q, PENG J Y, et al. Application of in-service high pressure wellhead testing technology [J]. Journal of Beijing Institute of Petrochemical Technology, 2018,26(4):43-47.
- [ 2 ] 曾莉. 管道弯管段冲刷腐蚀机理与流体动力学特征[D]. 武汉:华中科技大学,2017.  
ZENG L. Scour corrosion mechanism and fluid dynamics characteristics of pipe bend section [D]. Wuhan: Huazhong University of Science and Technology,2017.
- [ 3 ] 何天隆,李昊燃,程远鹏,等. 基于新型GM(1,N)模型的油气管道腐蚀速率预测[J]. 腐蚀与防护,2021,42(10):79-85.  
HE T L, LI H R, CHENG Y P, et al. Corrosion rate prediction of oil and gas pipelines based on new GM (1, N) model [J]. Corrosion and Protection, 2021, 42(10):79-85.
- [ 4 ] CHEN X, WANG L, HUANG Z. Principal component analysis based dynamic fuzzy neural network for internal corrosion rate prediction of gas pipelines [J]. Mathematical Problems in Engineering, 2020, 2020(12):1-9.
- [ 5 ] JIAN Q, AI Z. Internal and external defect identification of pipelines using the PSO-SVM method [J]. Insight Non-Destructive Testing and Condition Monitoring,2015, 57(2):85-91.
- [ 6 ] 李瑞莲,朱斌,周秀美,等. 基于数据驱动的金属供水管网铁腐蚀预测模型研究[J]. 中国给水排水,2019,35(11):54-58.  
LI R L, ZHU B, ZHOU X M, et al. Research on prediction model of iron corrosion in metal water supply network based on data drive [J]. China Water & Wastewater,2019,35(11):54-58.
- [ 7 ] 李丽,李晓刚,邢士波,等. BP神经网络对国内典型地区碳钢土壤腐蚀的预测研究[J]. 腐蚀科学与防护技术,2013,25(5):372-376.  
LI L, LI X G, XING SH B, et al. Prediction of soil corrosion of carbon steel by BP artificial neural network in typical regions of China [J]. Corrosion Science and Protection Technology,2013,25(5):372-376.
- [ 8 ] 段俊峰,李宁,唐求,等. 基于CK-GPR的多应力环境智能电表剩余寿命预测[J]. 仪器仪表学报,2021,42(4):102-110.  
DUAN J F, LI N, TANG Q, et al. Residual life prediction of smart electricity meter based on CK-GPR in multi-stress environment [J]. Chinese Journal of Scientific Instrument, 2021,42(4):102-110.
- [ 9 ] 陈佳鲜,毛文涛,刘京,等. 基于时间序列迁移递归预测的未知工况下滚动轴承在线剩余寿命评估[J]. 控制与决策,2023,38(1):112-122.  
CHEN J X, MAO W T, LIU J, et al. Online residual life evaluation of rolling bearings under unknown working conditions based on time series migration recursive prediction [J]. Control and Decision Making, 2023, 38(1):112-122.
- [ 10 ] 韩文海,周晶. 海底管道腐蚀模型对比研究[J]. 石油工程建设,2014,40(3):9-13.  
HAN W H, ZHOU J. Comparison of corrosion models for submarine pipelines [J]. Petroleum Engineering Construction,2014,40(3):9-13.
- [ 11 ] VELAZQUEZ J C, CALEYO F, VALOR A, et al. Predictive model for pitting corrosion in buried oil and gas pipelines [J]. Corrosion,2009,65(9):332-342.
- [ 12 ] CALEYO F, VELAZQUEZ J C, HALLEN J M. Probability distribution of pitting corrosion depth and rate in underground pipelines: A Monte Carlo study [J]. Corrosion,2009,51(7):1925-1934.
- [ 13 ] KALMAN R E. A new approach to linear filtering and prediction problems [J]. Journal of Basic Engineering, 1960, 82D:35-45.
- [ 14 ] 李江,王义伟,魏超,等. 卡尔曼滤波理论在电力系统中的应用综述[J]. 电力系统保护与控制,2014,42(6):135-144.  
LI J, WANG Y W, WEI CH, et al. Application of Kalman filter theory in power system [J]. Power System Protection and Control,2014,42(6):135-144.
- [ 15 ] 贾晨,邵永松,郭兰慧,等. 建筑结构用钢的大气腐蚀模型研究综述[J]. 哈尔滨工业大学学报,2020,

52(8):1-9.

JIA CH, SHAO Y S, GUO L H, et al. A review on atmospheric corrosion model of steel for building structure [J]. Journal of Harbin Institute of Technology, 2020, 52(8):1-9.

[16] LIU F CH, QIU D W. Diagnosability of fuzzy discrete-event systems: A fuzzy approach [J]: IEEE Transaction Fuzzy Systems, 2009, 17(2):372-384.

[17] 尤波, 陈翰南, 李佳钰, 等. 一种基于变权重的六足机器人共享遥操作控制 [J]. 仪器仪表学报, 2019, 40(8):239-250.

YOU B, CHEN H N, LI J Y, et al. A shared teleoperation control system for hexapod robot based on variable weight [J]. Chinese Journal of Scientific Instrument, 2019, 40(8):239-250.

[18] 何映思. 模糊推理方法及模糊逻辑形式系统研究[D]. 重庆:西南大学, 2011.

HE Y S. Research on fuzzy reasoning method and fuzzy logic formal system [D]. Chongqing: Southwest University, 2011.

[19] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8):1697-1716.

JIAO L CH, YANG SH Y, LIU F, et al. Neural networks: A review and prospect [J]. Chinese Journal of Computers, 2016, 39(8):1697-1716.

[20] DAYHOFF J E, DELEO J M. Artificial neural networks[J]. Cancer, 2001, 91(8):1615-1634.

作者简介



尹爱军(通信作者), 2006 年于重庆大学获博士学位, 2012 年重庆大学自动控制与理论博士后, 2013 年英国纽卡斯尔大学访问学者。现为重庆大学教授、博导, 主要研究方向为智能测试与仪器、装备故障预测与健康管理、大数据运维与人工智能、无损检测、机器视觉等方面的研究。

E-mail: aijun.yin@cqu.edu.cn

Yin Aijun (Corresponding author) received his Ph. D. degree from Chongqing University in 2006, postdoctoral fellow in automatic control and theory of Chongqing University in 2012,

and visiting scholar at Newcastle University in 2013. Currently, he is a professor and doctoral supervisor at Chongqing University. His main research interests include intelligent testing and instruments, equipment fault prediction and health management, big data operation and maintenance and artificial intelligence, nondestructive testing, machine vision, etc.



朱文浩, 2016 年于南京工程学院获得学士学位, 现为重庆大学在读研究生, 主要研究方向为智能监测与嵌入式设备。

E-mail: 1304147205@qq.com

Zhu Wenhao received his B. Sc. degree from Nanjing Institute of Technology in 2016.

Now he is a M. Sc. candidate at Chongqing University. His main research interests include intelligent monitoring and embedded devices.



任宏基, 分别在 2013 年, 2016 年和 2021 年于重庆大学获得工学学士、硕士、博士学位, 现为重庆电子工程职业学院讲师, 主要研究方向为智能测试与仪器、无损检测以及故障诊断。

E-mail: renhongji@cqet.edu.cn

Ren Hongji received his B. Sc. degree in mechatronics engineering, M. Sc. and Ph. D. degrees from Chongqing University in 2013, 2016 and 2021, respectively. Now he is a lecturer with Chongqing College of Electronic Engineering. His main research interests include intelligent testing and instruments, nondestructive testing and evaluation, and fault detection and diagnosis.



戴宗贤, 2011 年于重庆大学获得学士学位, 2014 年于重庆大学获得硕士学位, 现为重庆市计量质量检测研究院高级工程师, 主要研究方向为测量与测试技术。

E-mail: 623179025@qq.com

Dai Zongxian received B. Sc. degree from Chongqing University in 2011 and M. Sc. degree from Chongqing University in 2014. He is now a senior engineer of Chongqing Institute of Measurement and Quality Testing. His main research interests include measurement and testing technology.