

盐穴储气库注采管柱内腐蚀速率预测模型研究

骆正山, 欧阳长风, 王小完, 张新生

(西安建筑科技大学 管理学院, 西安 710055)

摘要: **目的** 提升盐穴储气库注采管柱的内腐蚀速率预测精度, 以保障盐穴储气库的设施健康和运行安全。**方法** 建立基于小波核主成分分析 (KPCA) 和改进灰狼算法 (IGWO) 优化的极限学习机 (ELM) 腐蚀速率预测模型。以某盐穴储气库注采管柱为例。首先选取 10 种腐蚀影响因素, 建立盐穴储气库注采管柱的内腐蚀指标体系; 其次通过小波 KPCA 提取影响注采管柱内腐蚀的关键特征, 后利用 IGWO 对 ELM 模型参数 ω_j 和 b_j 进行迭代寻优, 进而建立 IGWO-ELM 盐穴储气库注采管柱内腐蚀速率预测模型; 最后在 MATLAB 中进行仿真计算, 将 IGWO-ELM 模型与 ELM、PSO-ELM、SSA-ELM 模型进行预测误差对比。**结果** 经小波 KPCA 特征提取后得到包含 98.61% 原信息的 3 项主成分, IGWO-ELM 模型的预测结果与实际值吻合度高, 其均方根误差为 0.008 8, 平均绝对百分比误差为 0.260 9%, 决定系数 (R^2) 高达 0.992 5, 比其他 3 个对比模型的性能更优。**结论** 小波 KPCA 特征提取能力优良, IGWO-ELM 模型能够有效预测盐穴储气库注采管柱的内腐蚀速率, 为盐穴储气库注采管柱的腐蚀研究提供了新的思路与方法。

关键词: 盐穴储气库; 注采管柱; 腐蚀速率预测; 主成分分析法 (KPCA); 改进灰狼优化 (IGWO); 极限学习机 (ELM)

中图分类号: TG174 文献标识码: A 文章编号: 1001-3660(2022)06-0283-08

DOI: 10.16490/j.cnki.issn.1001-3660.2022.06.026

Research on Prediction Model of Internal Corrosion Rate in Injection and Production String of Salt Cavern Gas Storage

LUO Zheng-shan, OUYANG Chang-feng, WANG Xiao-wan, ZHANG Xin-sheng

(School of Management, Xi'an University of Architecture and Technology, Xi'an 710055, China)

ABSTRACT: The injection and production string of the salt cavern gas storage has been in a complex underground environment for a long time, making it susceptible to a variety of corrosion factors. This work aims to improve the prediction accuracy of the corrosion rate in the injection and production string of the salt cavern gas storage, thereby ensuring the health and operational safety of these facilities. To accomplish the above objectives, the solution proposed is to establish an internal corrosion rate prediction model based on wavelet kernel principal component analysis (KPCA) and an extreme learning machine (ELM) after improved gray wolf optimization (IGWO). First of all, in the actual operation data of the injection and production string of the salt cavern gas storage, 10 indicators with larger corrosion factors are selected, such as: partial pressure of carbon

收稿日期: 2021-04-28; 修订日期: 2021-12-07

Received: 2021-04-28; Revised: 2021-12-07

基金项目: 国家自然科学基金 (41877527); 陕西省社科基金 (2018S34)

Fund: National Natural Science Foundation of China (41877527); Shaanxi Provincial Social Science Fund (2018S34)

作者简介: 骆正山 (1969—), 男, 博士, 教授, 主要研究方向为油气管道风险评估。

Biography: LUO Zheng-shan (1969-), Male, Doctor, Professor, Research focus: oil and gas pipeline risk assessment.

引文格式: 骆正山, 欧阳长风, 王小完, 等. 盐穴储气库注采管柱内腐蚀速率预测模型研究[J]. 表面技术, 2022, 51(6): 283-290.

LUO Zheng-shan, OUYANG Chang-feng, WANG Xiao-wan, et al. Research on Prediction Model of Internal Corrosion Rate in Injection and Production String of Salt Cavern Gas Storage[J]. Surface Technology, 2022, 51(6): 283-290.

dioxide, hydrogen sulfide partial pressure, inner wall surface temperature, etc. Subsequently, the internal corrosion index system of the injection and production string of the salt cavern gas storage was established. Secondly, the wavelet KPCA is used to extract the key features that affect the internal corrosion rate of the injection and production string, and then IGWO is used to iteratively optimize the input weight matrix and hidden layer threshold of the ELM model, and stop the loop until the termination condition is met. Furthermore, a prediction model of corrosion rate in the injection and production string of IGWO-ELM salt cavern gas storage is established. Finally, numerical simulation and simulation calculation are carried out in MATLAB software, and the prediction errors of the IGWO-ELM model are compared with the three models of ELM, PSO-ELM and SSA-ELM respectively. The research results show that the wavelet KPCA effectively extracts the three principal components that contain 98.61% of the original information in the corrosion data of the injection-production pipe string of the salt cavern gas storage. Applying the reconstructed corrosion data to the ELM, PSO-ELM, SSA-ELM, and IGWO-ELM models, their average relative errors are 9.404 8%, 5.061 5%, 1.573 7%, and 0.707 3%. The prediction results of the IGWO-ELM model are in good agreement with the actual values. The root mean square error of the constructed IGWO-ELM model is 0.008 8, the average absolute percentage error is 0.260 9%, and the coefficient of determination (R^2) is as high as 0.992 5. Its prediction result is better than the other three comparison models. The kernel principal component analysis with the introduction of wavelet kernel function has an excellent ability to extract corrosion characteristics of the injection and production string of the salt cavern gas storage. Within the applicable range of certain working conditions, the established IGWO-ELM model can effectively predict the internal corrosion rate of the injection and production string of the salt cavern gas storage. It not only provides a reference basis for the integrity evaluation and risk warning of the injection and production system of the salt cavern gas storage, but also provides new ideas and methods for the corrosion study of the injection and production string of the salt cavern gas storage.

KEY WORDS: salt cavern gas storage; injection and production string; corrosion rate prediction; principal component analysis (KPCA); improved gray wolf optimization (IGWO); extreme learning machine (ELM)

近年来,我国天然气供需量稳步增长,高质量发展战略能源储备设施地下储气库具有重大意义^[1]。盐穴储气库具有孔隙率低、渗透率小、塑性形变能力强等优势^[2-3]。注采管柱是盐穴储气库的重要组成,长期处于地下复杂环境使其易受多种腐蚀因素的影响并造成运维灾害^[4-5]。因此,探究盐穴储气库注采管柱的腐蚀机理与规律,建立高精度的腐蚀预测模型意义重大。

目前,国内外学者已对管线腐蚀现象展开了大量研究。张新生等^[6]研究了海洋立管的腐蚀发展规律,建立了初始条件滑动的非等间距管道腐蚀预测灰色模型 SUGM (1,1, ρ)。Chen 等^[7]利用主成分分析法提取海底管道内腐蚀的关键腐蚀因素,消除冗余信息并确定管道失效原因。王晓敏等^[8]基于时变可靠性方法提出了一种多失效模式腐蚀影响下的地下管道失效概率预测方法。谢飞等^[9]从化学反应、电化学反应和传质过程 3 个方面探究了天然气管道 CO₂ 腐蚀机理,提出了基于腐蚀机理的腐蚀速率预测模型。但以上传统研究方法针对管线腐蚀预测问题仍存在不足: SUGM (1,1, ρ) 初始条件的确定方式复杂,大幅更新腐蚀数据对预测结果的准确性存在较大影响;主成分分析法仅适用于处理线性映射问题,对非线性数据的特征提取效果较差;基于时变可靠性的失效概率方法难以准确定义失效事件的关联性,预测前提存在主观因素;机理模型研究仅考虑在理想溶液环境内的单一

电化学腐蚀作用,未能考虑到非理想环境中管道的复杂流动等问题。随着智能信息处理技术的高速发展,大量智能优化算法得以应用于管道的腐蚀预测研究。凌晓等^[10]通过优化反向传播神经网络 (BPNN) 参数,对输油管道的内腐蚀速率进行了预测分析。骆正山等^[11]建立基于动态贝叶斯网络 (DBN) 的疲劳寿命模型,预测了海底腐蚀管道的失效概率。Peng 等^[12]通过优化支持向量回归 (SVR) 模型参数,对多相流管道的腐蚀速率进行了预测分析。曲志豪等^[13]利用网格搜索算法优化了随机森林回归模型,建立了 GA-RFC 模型并对油气管道腐蚀速率进行了预测。但上述智能算法仍存在不足: BPNN 存在结构复杂、训练速度慢、易陷入局部极小值等缺点; DBN 的先验概率假设具有较强的主观性,对于属性非完全独立的大规模样本适用性不佳; SVR 中参数的确定存在强随机性,使得模型预测结果的波动性较大; RFC 模型中含有噪声样本时容易发生过拟合现象。

综上,本文在核主成分分析中引入小波核函数,对盐穴储气库注采管柱内的腐蚀因素进行特征提取,利用改进灰狼优化算法优化极限学习机的输入权值矩阵和隐含层阈值,建立小波 KPCA-IGWO-ELM 的盐穴储气库注采管柱内腐蚀速率预测模型。在 MATLAB 中对比分析多种预测模型的仿真结果,验证所建模型的适用性与准确性,为盐穴储气库注采系统安全运行提供可靠支撑。

1 KPCA

核主成分分析^[14-16](KPCA)是在主成分分析^[17-18](PCA)的基础上加入了核函数概念,利用核函数将低维数据非线性映射至高维特征空间,然后使用 PCA 进行降维,并最终实现数据线性化的一种特征提取方法。设数据集 $\mathbf{X} = \{x_1, x_2, \dots, x_i\} (i=1, 2, \dots, m)$, $x_i \in \mathbf{R}^n$, 其中 m 为样本数量, n 为样本维度。通过非线性映射函数 φ 将 x_i 映射到高维特征空间 \mathbf{S} , 并满足 $\sum_{i=1}^m \varphi(x_i) = 0$, 则可求得高维特征空间的协方差矩阵 $\bar{\mathbf{C}}$:

$$\bar{\mathbf{C}} = \frac{1}{m} \sum_{i=1}^m \varphi(x_i) \varphi(x_i)^T \quad (1)$$

协方差矩阵 $\bar{\mathbf{C}}$ 的特征值为 $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$ 且 $\lambda_n \geq 0$, 对应的特征向量为 $\mathbf{v} = \{v_1, v_2, \dots, v_n\}$, $\mathbf{v} \in \mathbf{S}$, 在满足 $\bar{\mathbf{C}}\mathbf{v} = \lambda\mathbf{v}$ 的情况下求特征方程可得:

$$\varphi(x_k) \bar{\mathbf{C}} \cdot \mathbf{v} = \lambda \varphi(x_k) \cdot \mathbf{v} \quad (2)$$

将特征向量 \mathbf{v} 线性表示为: $\mathbf{v} = \sum_{i=1}^m \alpha_i \varphi(x_i)$, 则有:

$$\frac{1}{m} \sum_{i=1}^m \alpha_i \sum_{j=1}^m [\varphi(x_k) \varphi(x_j)] [\varphi(x_j) \varphi(x_i)] = \lambda \sum_{i=1}^m \alpha_i [\varphi(x_k) \varphi(x_i)] \quad (3)$$

令核矩阵 $\mathbf{K} = \mathbf{K}(x_i, x_j) = [\varphi(x_i) \cdot \varphi(x_j)] (i, j=1, 2, \dots, n)$, 将 \mathbf{C} 和 \mathbf{v} 代入式(2)中可得 $\mathbf{K}\boldsymbol{\alpha} = n\lambda\boldsymbol{\alpha}$, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$, 其中 λ 和 $\boldsymbol{\alpha}$ 分别为核矩阵 \mathbf{K} 的特征值和特征向量。 $\bar{\mathbf{C}}$ 的归一化特征向量为 $\mathbf{v}^k (k=1, 2, \dots, m)$, 则样本 \mathbf{X} 的第 k 个主成分可表示为:

$$h_k = \mathbf{v}^k \varphi(x) = \sum_{i=1}^m \alpha_i^k \mathbf{K}(x_i, x_j) \quad (4)$$

利用 Morlet 母小波函数 $h(x) = \cos(1.75x) \cdot \exp(-x^2/2)$ 推导出的小波核函数公式为^[19]:

$$k(x_i, x_j) = \prod_{i=1}^n h\left(\frac{x_i - x_j}{\varepsilon}\right) = \prod_{i=1}^n \left[\cos\left(1.75 \times \frac{x_i - x_j}{\varepsilon}\right) \cdot \exp\left(-\frac{\|x_i - x_j\|^2}{2\varepsilon^2}\right) \right] \quad (5)$$

式中: ε 为伸缩因子, $\varepsilon, x_i, x_j \in \mathbf{R}^n$ 。

2 IGWO-ELM 模型

2.1 ELM

极限学习机^[20-22](ELM)是一种求解单隐含层前馈神经网络的机器学习算法,目前已成熟应用于回归、预测等领域。ELM 参数生成的随机性简化了神经网络隐含层的迭代过程,相较于其他传统模型具有

训练参数少、学习速度快、泛化能力强等优势。ELM 训练迭代神经网络得到最优 β_j , 使得预测值 y_i 训练误差最小,具体数学描述如下。

$$y_i = \sum_{j=1}^l g(\omega_j \cdot x_i + b_j) \cdot \beta_j, i=1, 2, \dots, N \quad (6)$$

式中: x_i 为输入参数; y_i 为输出参数; $g(x)$ 为激活函数; ω_j 为输入权值矩阵; b_j 为隐含层阈值; β_j 为输出权值矩阵; l 为隐含层节点数; N 为样本数量。式(6)可用矩阵表示:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Q} \quad (7)$$

求解线性方程组式(7)得到最小二乘解:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{Q} \quad (8)$$

式中: \mathbf{H}^+ 为矩阵 \mathbf{H} 的 Moore-Penrose 广义逆矩阵。

2.2 IGWO

改进灰狼优化^[23](IGWO)是 Mirjalili 等人于 2020 年提出的一种新型群体智能优化算法,算法在灰狼优化^[24](GWO)的基础上引入了基于维度学习狩猎(DLH)的改进搜索策略,有效解决了 GWO 种群多样性差、后期收敛速度慢、易陷入局部最优等缺点。

IGWO 中 α 、 β 、 δ 分别代表第 1、第 2、第 3 等级的狼, ω 为其余最低等级的狼。狼群在捕猎过程中严格遵守等级制度,低层级狼必须服从高层级狼的领导。设搜索空间维度为 d , 界限范围为 $[l_j, u_j]$, 狼群数量为 N , 第 i 只狼的位置定义为 $X_i(t) = \{x_{i1}, x_{i2}, \dots, x_{id}\}$, 狼群初始位置用式(9)表示。

$$X_{ij} = l_j + \text{rand}_j[0, 1] \times (u_j - l_j), i \in [1, N], j \in [1, d] \quad (9)$$

灰狼与猎物的距离 D 用式(10)表示,其位置更新如式(11)所示。

$$D = |C \times X_p(t) - X(t)| \quad (10)$$

$$X_i(t+1) = X_p(t) - A \times D \quad (11)$$

式中: t 为当前迭代次数; $X_p(t)$ 为第 t 次迭代时猎物的位置; $X_i(t)$ 为第 i 只狼在第 t 次迭代时的位置。通过调整收敛因子 A 和系数常量 C , 灰狼可进行位置更新,计算方法如式(12) — (14)所示。

$$A = 2 \times A \times r_1 - a(t) \quad (12)$$

$$C = 2 \times r_2 \quad (13)$$

$$a(t) = 2 - (2 \times t) / t_{\max} \quad (14)$$

式中: r_1 、 $r_2 \in [0, 1]$ 为随机数; t_{\max} 为最大迭代次数。捕猎行为由 α 、 β 、 δ 狼发起, ω 狼则根据 α 、 β 、 δ 的位置更新自己的位置,更新公式如式(15) — (17)所示。

$$\begin{cases} D_\alpha = |C_1 \times X_\alpha - X(t)| \\ D_\beta = |C_2 \times X_\beta - X(t)| \\ D_\delta = |C_3 \times X_\delta - X(t)| \end{cases} \quad (15)$$

$$\begin{cases} X_{i1}(t) = X_{\alpha}(t) - A_{i1} \times D_{\alpha}(t) \\ X_{i2}(t) = X_{\beta}(t) - A_{i2} \times D_{\beta}(t) \\ X_{i3}(t) = X_{\delta}(t) - A_{i3} \times D_{\delta}(t) \end{cases} \quad (16)$$

$$X_i(t+1) = \frac{X_{i1}(t) + X_{i2}(t) + X_{i3}(t)}{3} \quad (17)$$

式中: D_{α} 、 D_{β} 、 D_{δ} 分别表示 α 、 β 、 δ 狼与 ω 狼的距离; $X_i(t+1)$ 为每次更新后的灰狼位置。令 $X_{i-GWO}(t+1)$ 为灰狼位置更新候选者, IGWO 利用式 (18) 计算出当前位置 $X_i(t)$ 与候选位置 $X_{i-GWO}(t+1)$ 之间的距离半径 $R_i(t)$, 再由式 (19) 构造 $X_i(t)$ 的邻域 $N_i(t)$ 。

$$R_i(t) = \|X_i(t) - X_{i-GWO}(t+1)\| \quad (18)$$

$$N_i(t) = \{X_j(t) | D_i[X_i(t), X_j(t)] \leq R_i(t)\} \quad (19)$$

式中: D_i 为 $X_i(t)$ 与 $X_j(t)$ 之间的距离。在邻域 $N_i(t)$ 选取随机位置 $X_{n,d}(t)$ 和 $X_{r,d}(t)$, 计算式 (20) 得出灰狼位置更新另一候选者。

$$X_{i-DLH,d}(t+1) = X_{i,d}(t) + \text{rand}[X_{n,d}(t) - X_{r,d}(t)] \quad (20)$$

通过式 (21) 比较 $X_{i-GWO}(t+1)$ 和 $X_{i-DLH}(t+1)$ 的适应度值并确定下一阶段灰狼的更新位置。

$$X_i(t+1) = \begin{cases} X_{i-GWO}(t+1), & \text{if } f(X_{i-GWO}) < f(X_{i-DLH}) \\ X_{i-DLH}(t+1), & \text{otherwise} \end{cases} \quad (21)$$

重复以上过程, 当迭代次数等于最大迭代次数时循环结束, 输出最优适应度值作为猎物最终位置, IGWO 获全局最优解。

2.3 IGWO-ELM 预测模型构建

ELM 的预测性能取决于随机生成的输入权值矩阵 ω_j 和隐含层阈值 b_j , 利用 IGWO 对 ω_j 和 b_j 两参数进行迭代寻优, 进而建立 IGWO-ELM 预测模型, 模型流程如图 1 所示。

首先, 对样本做预处理, 设置 IGWO 中的 5 个初始化参数, 即狼群规模 N 、搜索空间维数 D 、种群上界 u_j 与下界 l_j 以及最大迭代次数 t_{\max} ; 其次, 以均方根误差函数作为适应度函数, 计算每只狼的初始适应度值并进行排序, 其中适应度函数值最优者为当前最优位置, 即 α 狼位置; 当前迭代次数在未达到最大迭代次数时, 狼群个体位置按照式 (21) 进行移动更新, 同时计算移动更新后每一个体的适应度函数值, 并依据数值大小进一步更新猎物位置; 最后, 当满足终止条件时停止迭代, 输出当前 ω_j 和 b_j 作为最优输入权值矩阵和隐含层阈值并赋予 ELM 模型, 得出相关腐蚀速率预测结果。

2.4 预测模型评价指标

本文选用均方根误差 (E_{RMSE})、平均绝对百分比误差 (E_{MAPE}) 和决定系数 (R^2) 3 个指标^[25]对 IGWO-ELM 模型预测结果进行评价, 计算公式见式 (22) — (24)。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (22)$$

$$E_{\text{MAPE}} = 100\% \times \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (23)$$

$$R^2 = \frac{\left(n \sum_{i=1}^n y_i \hat{y}_i - \sum_{i=1}^n y_i \sum_{i=1}^n \hat{y}_i \right)^2}{\left[n \sum_{i=1}^n \hat{y}_i^2 - \left(\sum_{i=1}^n \hat{y}_i \right)^2 \right] \left[n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2 \right]} \quad (24)$$

式中: n 为测试样本总量; y_i 为第 i 个样本的实际值; \hat{y}_i 为第 i 个样本的预测值。 E_{RMSE} 与 E_{MAPE} 指标的数值越小, 说明预测精度越高。 R^2 取值范围为 $[0, 1]$, 取值越趋近于 1, 表明模型的预测误差越小、性能越优。

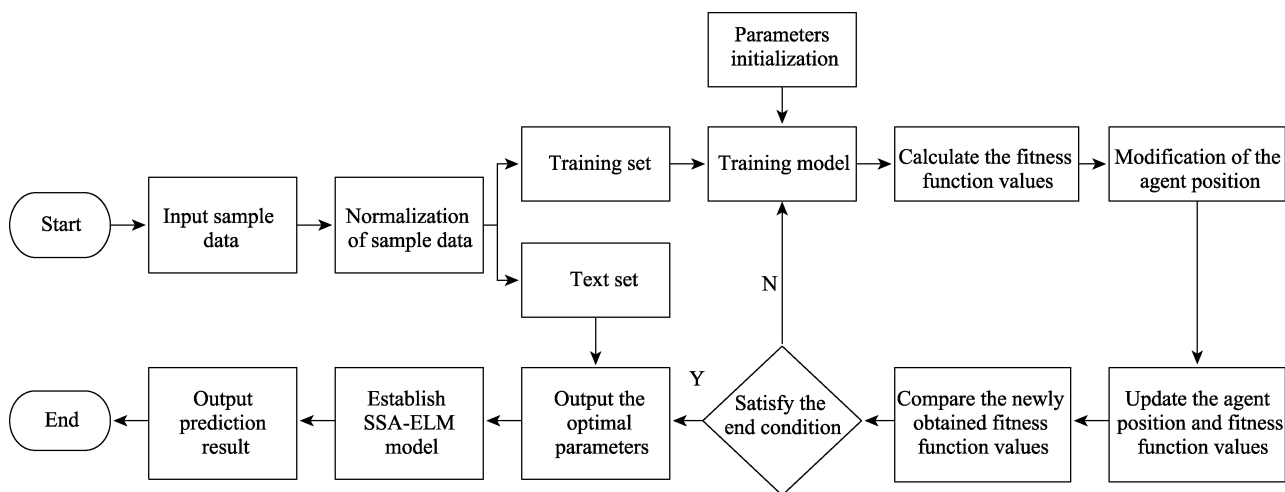


图 1 IGWO-ELM 模型腐蚀预测流程
Fig.1 Corrosion prediction flowchart of IGWO-ELM model

3 实例应用

3.1 指标构建与数据采集

以某盐穴储气库注采管柱的实测试验为例, 选取 10 种常见腐蚀因素构建盐穴储气库注采管柱的内腐蚀指标体系, 如图 2 所示。结合项目运行资料, 设定预测模型工况条件适用范围如表 1 所示, 取 250 组实测数据用作预测模型样本, 部分数据见表 2。




图 2 盐穴储气库注采管柱的内腐蚀指标体系
Fig.2 Internal corrosion index system of injection and production string in salt cavern gas storage

3.2 特征提取

将采集的 250 组数据做归一化处理, 后用小波 KPCA 对腐蚀指标进行特征提取, 得出综合腐蚀因素特征值与贡献率, 如表 3 所示。

KPCA 规定, 被选主成分的累计贡献率应不低于 95%。分析表 3 易知, 前 3 项主成分的累计贡献率高

表 1 预测模型工况适用范围
Tab.1 Application range of prediction model

Index	Lower limit	Upper limit
Partial pressure of carbon dioxide μ_1/MPa	0.005	0.210
Hydrogen sulfide partial pressure μ_2/MPa	0.000 2	0.010 5
Inner wall surface temperature $\mu_3/^{\circ}\text{C}$	25.0	70.0
pH value μ_4	4.5	8.0
Operating pressure μ_5/MPa	7.0	16.0
Medium flow rate $\mu_6/(\text{m} \cdot \text{s}^{-1})$	1.5	5.5
Moisture content $\mu_7/\%$	6.0	50.0
Chloride ion content $\mu_8/\%$	0.01	0.03
Sulfate content $\mu_9/\%$	0.01	0.07
Wall shear stress μ_{10}/Pa	25.0	115.0

达 98.61%, 故将前 3 项作为影响盐穴储气库注采管柱内腐蚀的特征指标。

3.3 腐蚀速率预测结果分析

IGWO 初始参数设定: $N = 30$, $D = 300$, $ub=1$, $lb = -1$, $t_{\max}=100$ 。选取 200 组腐蚀数据对预测模型进行训练, 利用 IGWO 优化 ELM 的 ω_j 和 b_j , 其适应度收敛曲线如图 3 所示。

由图 3 可知, 训练模型在 $t = 66$ 处收敛并获得最优适应度值。此时得到的 ω_j 和 b_j 为最优参数, 将其赋予并建立 IGWO-ELM 盐穴储气库注采管柱内腐蚀速率预测模型。

将训练好的 IGWO-ELM 对其余 50 组腐蚀数据进行测试。为体现 IGWO-ELM 预测模型的准确性, 选用 ELM、PSO-ELM、SSA-ELM 对相同数据进行预测分析, 模型的预测结果对比见图 4, 预测相对误差对比见图 5。表 4 为分别用高斯核函数和小波核函数进行特征提取后, 4 个预测模型的相对误差分析结果。

表 2 盐穴储气库注采管柱的内腐蚀数据
Tab.2 Internal corrosion data of injection and production string in salt cavern gas storage

Samples	μ_1/MPa	μ_2/MPa	$\mu_3/^{\circ}\text{C}$	μ_4	μ_5/MPa	$\mu_6/(\text{m} \cdot \text{s}^{-1})$	$\mu_7/\%$	$\mu_8/\%$	$\mu_9/\%$	μ_{10}/Pa	$V/(\text{mm} \cdot \text{a}^{-1})$
1	0.018	0.000 6	42.6	6.24	10.2	3.3	13.57	0.014 1	0.017 7	69.9	0.021
2	0.012	0.000 7	45.4	6.19	14.8	2.8	18.28	0.012 7	0.014 1	58.2	0.059
3	0.034	0.000 7	51.3	6.11	10.7	4.3	32.45	0.012 8	0.036 1	38.2	0.009
4	0.009	0.000 8	49.1	5.83	9.9	4.5	44.45	0.024 2	0.017 3	45.7	0.048
5	0.017	0.001 0	52.4	6.97	13.6	3.7	44.12	0.012 1	0.021 6	50.1	0.016
...
246	0.028	0.001 7	61.0	5.39	11.5	3.5	40.06	0.020 5	0.027 3	62.5	0.056
247	0.025	0.002 0	57.8	6.33	13.0	4.6	32.51	0.019 4	0.019 5	52.3	0.096
248	0.015	0.002 5	62.4	7.25	11.4	3.9	28.34	0.013 7	0.037 3	52.1	0.354
249	0.018	0.001 1	59.2	6.30	10.6	3.2	19.52	0.014 4	0.027 2	52.5	0.057
250	0.032	0.001 8	48.0	6.09	12.9	2.9	20.61	0.014 2	0.019 0	44.7	0.084

表 3 特征变量提取

Tab.3 Extraction of characteristic variables

Principal components	Eigen values	Contribution rate/%	Cumulative contribution rate/%
1	0.363 6	54.19	54.19
2	0.158 5	23.63	77.82
3	0.139 5	20.79	98.61
4	0.006 2	0.92	99.53
5	0.001 3	0.19	99.72
6	$7.296\ 7 \times 10^{-4}$	0.21	99.93
7	$3.341\ 8 \times 10^{-4}$	0.07	100




图 3 IGWO-ELM 适应度收敛曲线

Fig.3 Fitness convergence curve of IGWO-ELM




图 4 预测结果对比图

Fig.4 Comparison chart of forecast result




图 5 预测相对误差对比图

Fig.5 Comparison chart of forecast relative error

表 4 不同核函数的预测结果相对误差分析

Tab.4 Relative error analysis of prediction results of different kernel functions

Test samples	Relative error of prediction using gaussian KPCA				Relative error of prediction using wavelet KPCA			
	ELM	PSO-ELM	SSA-ELM	IGWO-ELM	ELM	PSO-ELM	SSA-ELM	IGWO-ELM
1	8.903 8	4.285 4	2.963 6	1.361 4	6.949 0	3.817 3	1.962 2	0.753 8
2	6.459 4	6.149 3	1.982 9	0.928 7	4.329 7	3.959 6	0.942 6	0.826 1
3	7.159 3	5.956 6	2.704 4	1.338 0	6.235 1	4.751 5	1.596 3	0.574 7
4	10.634 7	6.543 2	2.690 8	1.285 3	7.542 0	5.061 4	1.412 4	0.712 8
5	14.662 8	8.926 3	2.247 6	1.438 2	9.235 4	4.987 0	1.752 5	0.683 0
6	17.250 8	12.997 6	3.520 7	1.623 9	12.940 7	6.901 9	1.836 7	0.644 7
7	24.627 2	11.106 9	2.034 4	1.015 6	18.601 5	5.951 8	1.513 0	0.756 3
Mean relative error/%	12.814 0	7.995 0	2.592 1	1.284 4	9.404 8	5.061 5	1.573 7	0.707 3

由图 4 可知,相较于 ELM、PSO-ELM 和 SSA-ELM, IGWO-ELM 的预测结果更接近于实际值,拟合程度更高。分析图 5 和表 4 可知,经小波 KPCA 的模型预测性能均优于经高斯 KPCA 的模型,且经小波 KPCA 的 ELM、PSO-ELM、SSA-ELM、IGWO-ELM 的平均相对误差分别为 9.404 8%、5.061 5%、1.573 7%、0.707 3%,相较于经高斯 KPCA 的平均相对误差分别降低了 3.409 2%、2.933 5%、1.018 4%、0.577 1%,说明小波 KPCA-IGWO-ELM 模型的性能

提升较大。为验证模型的预测效果,采用 2.4 节中的 3 项指标分别对 4 种预测模型进行评价分析,结果见表 5。

由表 5 可知,IGWO-ELM 的 R^2 高达 0.992 5,其 E_{RMSE} 和 E_{MAPE} 分别比 ELM 降低了 0.116 6、16.175 1%,比 PSO-ELM 降低了 0.073 2、8.410 6%,比 SSA-ELM 降低了 0.072 3、4.656 7%。在一定工况条件适用范围内,说明 IGWO-ELM 模型的性能优良,盐穴储气库注采管柱内腐蚀速率的预测结果更精准。

表 5 模型性能评价指标对比
Tab.5 Comparison of model performance
evaluation indicators

Samples	E_{RMSE}	$E_{MAPE}/\%$	R^2
ELM	0.125 4	16.436 0	0.385 7
PSO-ELM	0.082 0	8.671 5	0.398 5
SSA-ELM	0.081 1	4.917 6	0.436 4
IGWO-ELM	0.008 8	0.260 9	0.992 5

4 结论

1)利用小波 KPCA 提取出包含 98.61%腐蚀信息的 3 项主成分, 基于此的预测结果相对误差最小。经小波 KPCA 的 ELM、PSO-ELM、SSA-ELM、IGWO-ELM 的平均相对误差分别为 9.404 8%、5.061 5%、1.573 7%、0.707 3%, 相较于经高斯 KPCA 的平均相对误差分别降低了 3.409 2%、2.933 5%、1.018 4%、0.577 1%。

2) 基于 DLH 搜索策略的 IGWO 解决了 ELM 中 ω_j 和 b_j 选择随机性强的问题, 显著提升了预测模型的泛化性能。IGWO-ELM 预测结果的 E_{RMSE} 为 0.008 8, E_{MAPE} 为 0.260 9%, R^2 为 0.992 5, 均优于 ELM、PSO-ELM、SSA-ELM 的预测结果。证明模型能够有效预测盐穴储气库注采管柱的内腐蚀速率, 为盐穴储气库注采系统的完整性评价和风险预警提供参考依据。

参考文献:

[1] 魏国齐, 郑雅丽, 邱小松, 等. 中国地下储气库地质理论与应用[J]. 石油学报, 2019, 40(12): 1519-1530.
WEI Guo-qi, ZHENG Ya-li, QIU Xiao-song, et al. Geological Theory and Application of Underground Gas Storage in China[J]. Acta Petrolei Sinica, 2019, 40(12): 1519-1530.

[2] 完颜祺琪, 丁国生, 赵岩, 等. 盐穴型地下储气库建库评价关键技术及其应用[J]. 天然气工业, 2018, 38(5): 111-117.
WANYAN Qi-qi, DING Guo-sheng, ZHAO Yan, et al. Key Technologies for Salt-Cavern Underground Gas Storage Construction and Evaluation and Their Application[J]. Natural Gas Industry, 2018, 38(5): 111-117.

[3] WANG Tong-tao, YANG Chun-he, CHEN Jia-song, et al. Geomechanical Investigation of Roof Failure of China's First Gas Storage Salt Cavern[J]. Engineering Geology, 2018, 243: 59-69.

[4] LIU Wei, CHEN Jie, JIANG De-yi, et al. Tightness and Suitability Evaluation of Abandoned Salt Caverns Served as Hydrocarbon Energies Storage under Adverse Geological Conditions (AGC)[J]. Applied Energy, 2016, 178: 703-720.

[5] CHEN Xiang-sheng, LI Yin-ping, LIU Wei, et al. Study on Sealing Failure of Wellbore in Bedded Salt Cavern Gas

Storage[J]. Rock Mechanics and Rock Engineering, 2019, 52(1): 215-228.

[6] 张新生, 叶晓艳. 不同初始条件的 UGM(1,1)管道腐蚀预测建模研究[J]. 中国安全科学学报, 2019, 29(3): 63-69.
ZHANG Xin-sheng, YE Xiao-yan. Study on UGM(1,1) Modeling for Prediction of Pipes Corrosion under Different Initial Conditions[J]. China Safety Science Journal, 2019, 29(3): 63-69.

[7] CHEN Xiao-xu, WANG Lin-yuan, HUANG Zhi-yu. Principal Component Analysis Based Dynamic Fuzzy Neural Network for Internal Corrosion Rate Prediction of Gas Pipelines[J]. Mathematical Problems in Engineering, 2020, 2020: 3681032.

[8] 王晓敏, 骆正山, 高懿琼, 等. 基于多种失效模式及其随机相关性的地下管道腐蚀可靠性分析[J]. 表面技术, 2022, 51(4): 202-210.
WANG Xiao-min, LUO Zheng-shan, GAO Yi-qiong, et al. Reliability Analysis of Corrosion Affected Underground Steel Pipes Considering Multiple Failure Modes and Their Stochastic Correlations[J]. Surface Technology, 2022, 51(4): 202-210.

[9] 谢飞, 李佳航, 王新强, 等. 天然气管道 CO₂ 腐蚀机理及预测模型研究进展[J]. 天然气工业, 2021, 41(10): 109-118.
XIE Fei, LI Jia-hang, WANG Xin-qiang, et al. Research Progress on CO₂ Corrosion Mechanism and Prediction Model of Natural Gas Pipelines[J]. Natural Gas Industry, 2021, 41(10): 109-118.

[10] 凌晓, 徐鲁帅, 余建平, 等. 基于改进的 BP 神经网络的输油管道内腐蚀速率预测[J]. 传感器与微系统, 2021, 40(2): 124-127.
LING Xiao, XU Lu-shuai, YU Jian-ping, et al. Prediction of Corrosion Rate in Oil Pipeline Based on Improved BP Neural Network[J]. Transducer and Microsystem Technologies, 2021, 40(2): 124-127.

[11] 骆正山, 赵乐新, 王小完. 基于动态贝叶斯网络的海底管道点蚀疲劳损伤失效模型研究[J]. 表面技术, 2020, 49(1): 269-275.
LUO Zheng-shan, ZHAO Le-xin, WANG Xiao-wan. Failure Model for Pitting Fatigue Damaged Pipeline of Subsea Based on Dynamic Bayesian Network[J]. Surface technology, 2020,49(1): 269-275.

[12] PENG Shan-bi, ZHANG Zhe, LIU En-bin, et al. A New Hybrid Algorithm Model for Prediction of Internal Corrosion Rate of Multiphase Pipeline[J]. Journal of Natural Gas Science and Engineering, 2021, 85: 103716.

[13] 曲志豪, 唐德志, 胡丽华, 等. 基于优化随机森林的 H₂S 腐蚀产物类型及腐蚀速率预测[J]. 表面技术, 2020, 49(3): 42-49.
QU Zhi-hao, TANG De-zhi, HU Li-hua, et al. Prediction of H₂S Corrosion Products and Corrosion Rate Based on Optimized Random Forest[J]. Surface Technology, 2020, 49(3): 42-49.

[14] SCHÖLKOPF B, SMOLA A, MÜLLER K R. Nonlinear

- Component Analysis as a Kernel Eigenvalue Problem[J]. Neural Computation, 1998, 10(5): 1299-1319.
- [15] FEZAI R, MANSOURI M, TAOUALI O, et al. Online Reduced Kernel Principal Component Analysis for Process Monitoring[J]. Journal of Process Control, 2018, 61: 1-11.
- [16] HU Qin, QIN Ai-song, ZHANG Qing-hua, et al. Fault Diagnosis Based on Weighted Extreme Learning Machine with Wavelet Packet Decomposition and KPCA[J]. IEEE Sensors Journal, 2018, 18(20): 8472-8483.
- [17] BRO R, SMILDE A K. Principal Component Analysis[J]. Anal Methods, 2014, 6(9): 2812-2831.
- [18] JOLLIFFE I T, CADIMA J. Principal Component Analysis: A Review and Recent Developments[J]. Philosophical Transactions Series A, Mathematical, Physical, and Engineering Sciences, 2016, 374(2065): 20150202.
- [19] 迟恩楠, 李春祥. 基于优化组合核和 Morlet 小波核的 LSSVM 脉动风速预测方法[J]. 振动与冲击, 2016, 35(18): 52-57.
- CHI En-nan, LI Chun-xiang. Forecast of Fluctuating Wind Velocity Using LSSVM with Optimized Combination Kernel and Morlet Wavelet Kernel[J]. Journal of Vibration and Shock, 2016, 35(18): 52-57.
- [20] HUANG Guang-bin, ZHU Qin-yu, SIEW C K. Extreme Learning Machine: Theory and Applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [21] HUANG Guang-bin, ZHOU Hong-ming, DING Xiao-jian, et al. Extreme Learning Machine for Regression and Multiclass Classification[J]. IEEE Transactions on Systems, Man, and Cybernetics Part B, Cybernetics: A Publication of the IEEE Systems, Man, and Cybernetics Society, 2012, 42(2): 513-529.
- [22] HUANG Gao, HUANG Guang-bin, SONG Shi-ji, et al. Trends in Extreme Learning Machines: A Review[J]. Neural Networks, 2015, 61: 32-48.
- [23] NADIMI-SHAHRAKI M H, TAGHIAN S, MIRJALILI S. An Improved Grey Wolf Optimizer for Solving Engineering Problems[J]. Expert Systems With Applications, 2021, 166: 113917.
- [24] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [25] 骆正山, 秦越, 张新生, 等. 基于 LASSO-WOA-LSSVM 的海洋管线外腐蚀速率预测[J]. 表面技术, 2021, 50(5): 245-252.
- LUO Zheng-shan, QIN Yue, ZHANG Xin-sheng, et al. Prediction of External Corrosion Rate of Marine Pipelines Based on LASSO-WOA-LSSVM[J]. Surface Technology, 2021, 50(5): 245-252.

责任编辑: 万长清

(上接第 254 页)

- [18] 乔家科, 孙波, 丁坤英, 等. 铝硅聚苯酯封严涂层全尺寸刮磨实验[J]. 表面技术, 2017, 46(7): 65-69.
- QIAO Jia-ke, SUN Bo, DING Kun-ying, et al. Full-Scale Bench Test of AlSi-Polyester Seal Coating[J]. Surface Technology, 2017, 46(7): 65-69.
- [19] 丁坤英, 秦晓庆, 孙波, 等. 热处理工艺对铝硅-聚苯酯涂层可磨耗性能的影响[J]. 焊接技术, 2014, 43(10): 26-29.
- DING Kun-ying, QIN Xiao-qing, SUN Bo, et al. Effect of Heat-Treatment on the Abradable of AlSi-Poly Coating[J]. Welding Technology, 2014, 43(10): 26-29.
- [20] 程旭莹, 刘建明, 章德铭, 等. 铝硅聚苯酯涂层热稳定性及与钛合金叶片对磨刮削可磨耗性研究[J]. 热喷涂技术, 2016, 8(1): 63-71.
- CHENG Xu-ying, LIU Jian-ming, ZHANG De-ming, et al. Thermal Stability of AlSi-Polyester Coating and Its Abradability Rubbed to Titanium Alloy Blade[J]. Thermal Spray Technology, 2016, 8(1): 63-71.
- [21] 陈亚军, 丁坤英, 王志平. 飞机发动机用 AlSi-Polyester 可磨耗封严涂层的热稳定性[J]. 焊接技术, 2009, 38(12): 7-10, 1.
- CHEN Ya-jun, DING Kun-ying, WANG Zhi-ping. Thermal Stability of AlSi-Polyester Abradable Seal Coating Used in an Aircraft Engine[J]. Welding Technology, 2009, 38(12): 7-10, 1.
- [22] 金辰日, 郭丹, 杨素媛, 等. 铝基可磨耗封严涂层的动态压缩力学行为[J]. 稀有金属材料与工程, 2020, 49(11): 3828-3834.
- JIN Chen-ri, GUO Dan, YANG Su-yuan, et al. Dynamic Compressive Behavior of Aluminum-Based Abradable Seal Coatings[J]. Rare Metal Materials and Engineering, 2020, 49(11): 3828-3834.
- [23] 刘正发, 温凤春, 王铮, 等. 叶片转速对铝硅聚苯酯涂层刮磨性能的影响[J]. 表面技术, 2016, 45(9): 112-117.
- LIU Zheng-fa, WEN Feng-chun, WANG Zheng, et al. Effects of Rotation Speed on Scraping Performance of AlSi Polyester Coating[J]. Surface Technology, 2016, 45(9): 112-117.
- [24] 田晔, 马江虹, 薛文涛, 等. 等离子喷涂镍基封严涂层热性能的研究[J]. 有色金属(冶炼部分), 2008(S1): 95-97.
- TIAN Ye, MA Jiang-hong, XUE Wen-tao, et al. Research on Thermal Behavior of Nickel-Based Seal Coatings by Plasma Spraying[J]. Nonferrous Metals (Extractive Metallurgy), 2008(S1): 95-97.
- [25] 刘凤伟, 李曙, 刘阳. 封严涂层材料及其可刮削性的评价[J]. 中国表面工程, 2009, 22(1): 12-18, 24.
- LIU Su-wei, LI Shu, LIU Yang. Seal Coating and Evaluation of Its Abradability[J]. China Surface Engineering, 2009, 22(1): 12-18, 24.

责任编辑: 万长清