

引文: 骆正山, 吕海鹏, 骆济豪. 基于 MWIWOA-SVM 的海底长输管道腐蚀速率预测[J]. 油气储运, 2025, 44(5): 551-559.

LUO Zhengshan, LYU Haipeng, LUO Jihao. Corrosion rate prediction for long-distance submarine pipelines based on MWIWOA-SVM[J]. Oil & Gas Storage and Transportation, 2025, 44(5): 551-559.

基于 MWIWOA-SVM 的海底长输管道腐蚀速率预测

骆正山¹ 吕海鹏¹ 骆济豪²

1. 西安建筑科技大学管理学院; 2. 北京理工大学信息与电子学院

摘要:【目的】为保障海底长输油气管道安全运行,需提高海底长输油气管道内腐蚀速率预测精度。现有模型多基于支持向量机(Support Vector Machine, SVM)建立,存在收敛精度低、寻优失衡以及易陷入局部最优等缺点。【方法】为解决以上问题,提出一种基于多途径提升的鲸鱼优化算法(Multi-Way Improved Whale Optimization Algorithm, MWIWOA)优化 SVM 的海底长输管道内腐蚀速率预测模型。通过 Tent 混沌映射结合反向学习机制初始化种群,引入自适应权重及非线性收敛因子平衡全局寻优和局部搜索功能,融合单纯形法改进拓张搜索方式,采用 Levy 飞行改进步长提升鲸鱼优化算法(Whale Optimization Algorithm, WOA)的寻优能力。基于 MWIWOA 对 SVM 模型核函数参数及惩罚因子寻优,提高参数选择的科学性。【结果】以 SP74-FPSO 管道段内管腐蚀数据为例,综合多种算法模型改进策略,分别构建 MWIWOA-SVM、WOA-SVM、PSO-SVM 以及 SVM 海底长输管道内腐蚀速率预测模型,并分别进行训练、预测及模拟结果对比。MWIWOA-SVM 海底长输管道内腐蚀速率预测模型的平均绝对百分比误差及均方根误差均低于 2%,处于极低水平,且决定系数与拟合度均达到 98%以上,内腐蚀速率预测值与真实值的相对误差不超过 0.99%。其各项性能指标均显著优于其他预测模型,预测精度更高。【结论】通过引入 MWIWOA 提高预测精度,其表现较对比模型更优,证明了改进算法的可行性,解决了算法模型初期所具有的收敛精度低、易局部最优以及算力不平衡易失衡等问题。根据实验结果, MWIWOA-SVM 海底长输管道内腐蚀速率预测模型具有良好的预测性能,可为后续海底管道风险评估及维修建议研究提供参考。(图 7, 表 3, 参 26)

关键词: 长输管道; SVM 回归预测; 多途径提升的鲸鱼优化算法; 内腐蚀速率

中图分类号: TE88

文献标识码: A

文章编号: 1000-8241(2025)05-0551-09

DOI: 10.6047/j.issn.1000-8241.2025.05.007

Corrosion rate prediction for long-distance submarine pipelines based on MWIWOA-SVM

LUO Zhengshan¹, LYU Haipeng¹, LUO Jihao²

1. School of Management, Xi'an University of Architecture and Technology; 2. School of Information and Electronics, Beijing Institute of Technology

Abstract: [Objective] To ensure the safe operation of long-distance submarine oil and gas pipelines, it is essential to enhance the prediction accuracy of their internal corrosion rates. Most existing models rely on Support Vector Machine (SVM), which has limitations including low convergence accuracy, unbalanced optimization, and a tendency to get stuck in local optima. [Methods] To address these issues, Multi-Way Improved Whale Optimization Algorithm (MWIWOA) was proposed to optimize the SVM-based prediction model for the internal corrosion rate of long-distance submarine pipelines. The population initialization utilized Tent chaotic mapping in conjunction with an opposition-based learning mechanism. Global optimization and local search functions were balanced through the introduction of adaptive weights and nonlinear convergence factors. The extended search mode was refined by integrating the simplex method, while the optimization capability of the Whale Optimization Algorithm (WOA) was enhanced with Levy flight to improve step length. Consequently, the improved WOA facilitated the optimization of kernel function parameters and penalty factors in the SVM-based model, thereby increasing the rigor of parameter selection. [Results] Using the corrosion data from the SP74-FPSO pipeline segment as a case study, various algorithm model

improvement strategies were applied to construct internal corrosion rate prediction models for long-distance submarine pipelines, including MWIWOA-SVM, WOA-SVM, PSO-SVM, and SVM. These models were trained to predict internal corrosion rates and subsequently compared against one another. The internal corrosion rate prediction model based on MWIWOA-SVM for long-distance submarine pipelines achieved an average absolute percentage error and root mean square error of less than 2%, indicating a very low error level. Both the determination coefficient and fitting degree exceeded 98%, while the relative error between the predicted and actual internal corrosion rates did not exceed 0.99%. These performance metrics significantly outperformed other prediction models, demonstrating higher prediction accuracy. **[Conclusion]** The successful implementation of the MWIWOA enhances prediction accuracy and outperforms comparative models, demonstrating the feasibility of the algorithm improvement. It effectively addresses issues such as low convergence accuracy, tendency to get stuck in local optima, and unbalanced computational power. The experimental results indicate that the MWIWOA-SVM-based prediction model for the internal corrosion rate of long-distance submarine pipelines demonstrates better prediction performance and effectiveness. This model can serve as a valuable reference for future research on risk assessment and maintenance recommendations for submarine pipelines. (7 Figures, 3 Tables, 26 References)

Key words: long-distance pipeline, prediction through SVM regression, MWIWOA, internal corrosion rate

目前,全球海底长输管道超过 8 000 km,已成为海底能源运输的“生命线”^[1]。海底长输管道外部环境复杂,内部则常伴随混合介质冲刷、内部管道压力及酸性离子等因素,极易发生腐蚀,导致穿孔泄漏,造成严重事故及巨大经济损失^[2]。因此,在海底长输管道腐蚀防控方面,构建科学可靠的内腐蚀速率预测模型具有重要意义。

目前,针对海底长输管道内腐蚀速率预测已有部分研究。骆正山等^[3]融合灰色关联分析与随机森林算法构建油气管道内腐蚀速率预测模型,但灰色关联分析只能表征变量与因变量之间关联度的相对大小,无法表现真实关联度的显著性。张梁等^[4-5]基于优化算法改进的 BP 神经网络建立腐蚀速率预测模型,但 BP 神经网络较依赖于大样本数据量的预测情形,具有样本依赖的局限性。Zhi 等^[6]建立时间序列长期预测遗传算法的灰色贝努利模型,实现了数据回归下的腐蚀预测。贾海韵等^[7]运用核主成分分析算法优化支持向量机(Support Vector Machine, SVM)、BP 神经网络等模型,并利用其预测海底管道内腐蚀风险,但其对非线性数据处理适应性能较差。Tian 等^[8]构建了遗传算法(Genetic Algorithm, GA)-SVM 模型,用于预测固有变形度,但 GA 存在易陷入早熟的缺点。Hatami 等^[9]通过耦合模拟退火算法进行 SVM 超参数寻优,但算法仅在 4 个影响因素下进行预测,寻优适应度低。梁晶晶等^[10-11]等使用灰狼优化(Grey Wolf Optimization, GWO)算法、粒子群优化(Particle Swarm Optimization, PSO)算法改进 SVM,用于预测海底管道腐蚀速率,

但 PSO、GWO 对数据适应性能较差,搜索能力不稳定,且种群构建及步长产生具有随机性,易陷入局部最优解。

总体上,现有机器学习研究均存在适应度低、易陷入局部最优等问题,尚未充分解决 SVM 模型在管道内腐蚀速率预测过程中的局限性。为解决上述问题,提出一种结合多途径改进鲸鱼算法(Multi-Way Improved Whale Optimization Algorithm, MWIWOA)优化 SVM 的海底管道内腐蚀速率预测模型。运用 MWIWOA 对 SVM 中的参数进行寻优,提高收敛速度与预测精度,同时通过改进步长搜索机制跳出局部最优。最后,以南海某海底长输管道腐蚀数据为实例,开展预测研究分析,并与原有模型进行统计学指标验证与对比。

1 理论基础

1.1 鲸鱼优化算法

鲸鱼优化算法(Whale Optimization Algorithm, WOA)是一种新型启发式优化算法,通过模拟鲸鱼群体的捕猎方式以搜寻猎物的最佳位置^[12]。其捕猎过程分为包围猎物、气泡螺旋捕食及随机搜索。如共有 N 只鲸鱼,则第 i 只鲸鱼在 d 维空间中的位置表示为: $X_i = (x_{1i}, x_{2i}, \dots, x_{di})$, $i = 1, 2, \dots, N$ 。WOA 具体搜索方式如下^[13]:

1)包围猎物。假定猎物当前处于初始最优解位置,鲸群对猎物展开包围机制并更新群体定位,表达式如下:

$$\begin{aligned}
 a &= 2 - 2(t/T_{\max}) \\
 A &= 2ar_1 - a \\
 C_1 &= 2r_2 \\
 D_1 &= |C_1 X_{\text{best}}(t) - X(t)| \\
 X(t+1) &= X_{\text{best}}(t) - AD_1
 \end{aligned} \tag{1}$$

式中: a 为常量, 其数值大小由 2 线性递减至 0; t 为当前迭代次数; T_{\max} 为最大迭代次数; C_1 、 A 分别为控制参数、收敛因子; r_1 、 r_2 为 $[0, 1]$ 内的随机数; D_1 为鲸鱼个体与猎物间的距离参数; $X_{\text{best}}(t)$ 为当前鲸鱼种群中的最优鲸鱼位置; $X(t)$ 、 $X(t+1)$ 分别为第 t 、 $t+1$ 次迭代鲸鱼个体位置。

2) 气泡螺旋捕食。在算法迭代过程中, 当概率 $p \geq 0.5$ 时进行螺旋围捕更新位置, 反之进行包围收缩:

$$D' = |X_{\text{best}}(t) - X(t)| \tag{2}$$

$$X(t+1) = D' e^{bl} \cos(2\pi l) + X_{\text{best}}(t) \tag{3}$$

式中: p 为 $[0, 1]$ 内的随机数; D' 为第 i 只鲸鱼与猎物之间的距离; b 为螺旋方程中的一个常量; l 为螺旋参数, 为 $[-1, 1]$ 内的随机数。

3) 随机搜索。当收敛因子 $|A| \geq 1$ 时, 鲸鱼会采取随机搜索策略更新自身位置。算法迭代中, 收敛因子 A 与概率 p 共同决定了鲸鱼个体的位置更新方式:

$$D_2 = |C_1 X_{\text{rand}}(t) - X(t)| \tag{4}$$

$$X(t+1) = X_{\text{rand}}(t) - AD_2 \tag{5}$$

式中: D_2 为鲸鱼与猎物间的距离参数; $X_{\text{rand}}(t)$ 为随机产生的鲸鱼个体位置;

1.2 支持向量机

SVM 是一种性能良好的分类算法, 能够寻找样本数据的统计特征, 提高回归分析的准确度^[14], 对于解决小样本、非线性以及高维模式识别具有明显的优越性, 可推广应用于人工智能、机器学习^[15-16]。SVM 核空间映射机制通过支持向量拓扑结构自适应性, 在核空间映射机制构建过程中, SVM 参数确定通常呈现特征空间映射关系自动推导的特性: 先依据样本分布特征动态捕获边界支持点, 再通过核宽度参数优化实现分类超平面校准, 避免局限性。可更好地将原始腐蚀参数间的复杂关联转换为高维空间中的线性可分模式, 最终建立适用于海底管道腐蚀速率预测的线性决策面。

2 改进鲸鱼优化算法模型

向 WOA 引入混沌映射反向学习、非线性收敛因

子和自适应权重、单纯形法、Levy 飞行步长 4 种改进策略, 形成 MWIWOA, 提高算法的收敛速度与精度, 增强寻优能力, 均衡全局与局部搜索算力, 避免陷入局部最优。

2.1 混沌映射反向学习

在 WOA 中, 个体初始位置使用伪随机数生成, 存在初始种群位置混乱、分布定位较难把控、丰富性较差的问题, 而初始种群的多样性及质量会直接影响 WOA 算法的整体精度。为解决此问题, 引入 Tent 混沌映射初始化种群^[17]。Tent 混沌映射具有随机性、遍历性好及非重复性, 可使初始种群生成分布更均匀, 规律性加强, 丰富群体多样性。Tent 混沌映射表达式为:

$$Z_{t+1} = \begin{cases} Z_t/\lambda, & Z_t \in [0, \lambda] \\ (1-Z_t)/(1-\lambda), & Z_t \in (\lambda, 1] \end{cases} \tag{6}$$

式中: 当 $t=0$ 时, Z_t 为 $(0, 1)$ 之间的随机数; λ 为混沌参数, 取值范围为 $[0, 1]$, 本文取 0.7。

设置混沌维数为 5 000, 由所产生的混沌种群分布(图 1)可见, 初始分布更加均匀且规律。

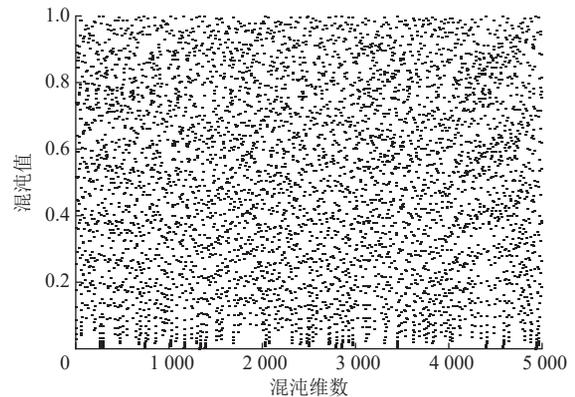


图 1 Tent 混沌种群分布图

Fig. 1 Tent chaotic population distribution

在引入 Tent 混沌映射均匀产生初始种群的基础上, 引入反向学习机制^[18]。反向学习是为每个初始候选解产生相应的反向解, 并从这两类解中选择适应度更优的解作为种群成员, 提高种群收敛速度与收敛精度^[19]。对混沌映射得到的初始化种群进行反向学习, 其数学模型表达式为:

$$O_{Y_{(t)}} = Y_{\min(t)} + Y_{\max(t)} - Z_t \tag{7}$$

式中: $O_{Y_{(t)}}$ 为个体反向学习幅度; $Y_{\min(t)}$ 、 $Y_{\max(t)}$ 分别为个体的下限、上限。

合并混沌映射种群及反向学习机制, 可提高种群

初始生成的随机性与多样性。

2.2 非线性收敛因子与自适应权重策略

在标准 WOA 中,随着迭代数量增加,算法的整体寻优能力逐步降低,由式(1)可知,收敛因子 A 随 a 的变化而改变, a 为随着迭代次数增加而线性递减的常数。为此,引入非线性收敛因子变化策略:

$$a = \frac{2}{1 + he^{t/T_{max}-1}} \quad (8)$$

式中: h 为控制常数,取 1.5。

由于标准 WOA 的惯性权重恒定为 1,在一定程度上限制了算法的搜索能力^[20],无法均衡全局探索与局部寻优的算力平衡。对此,在上述非线性收敛因子基础上提出一种新的自适应权重策略,对算法的全局搜索与局部寻优进行算力平衡,对猎物位置及包围收缩机制进行调整(图 2)。自适应权重 S_1 、 S_2 的数学表达式为:

$$\begin{cases} S_1 = -r[\cos(\pi t/T_{max}) - 1] \\ S_2 = r[\cos(\pi t/T_{max}) + 1] \end{cases} \quad (9)$$

式中: r 为权重常数,取 0.5。

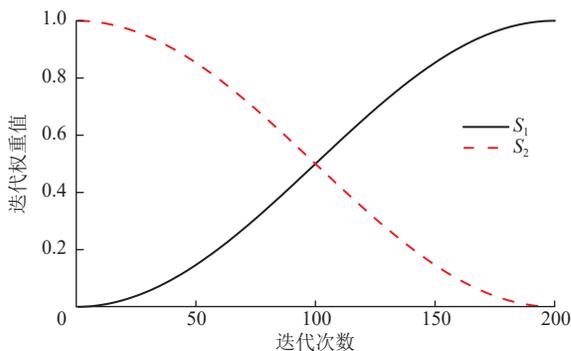


图 2 自适应权重随迭代次数变化曲线
Fig. 2 Adaptive weight variation curve with iteration count

随迭代次数增加, S_1 非线性递增,对式(3)的螺旋位置进行更新,自适应权重增加使得气泡螺旋捕猎可以充分向最优位置移动; S_2 非线性递减,在初期保持全局寻优能力,后期快速收敛且提高包围收缩精度,以此解决算法前期探索与后期寻优存在的算力不平衡的矛盾,提高算法整体性能。增加非线性收敛因子及自适应权重后的 WOA 位置更新表达式为:

$$X(t+1) = \begin{cases} X_{best}(t) - S_2AD_1, & p < 0.5 \quad |A| < 1 \\ X_{rand}(t) - S_2AD_2, & p < 0.5 \quad |A| \geq 1 \\ D'e^{bl} \cos(2\pi l) + S_1X_{best}(t), & p \geq 0.5 \end{cases} \quad (10)$$

2.3 单纯形法

在鲸鱼算法中,气泡螺旋机制会将寻优向单方面靠拢,搜索过程容易陷入局部最优,忽略多种可

性能最优解。单纯形法(Simple Method, SM)也称可变多面体搜索法,是一种无约束优化算法,通过映射、拓张、挤压等变换寻求一个较好解替代当前最差解^[21]。计算体量小、搜索速度快,具有较强的局部寻优能力。单纯形法通过迭代搜索的方式进行形状更替(图 3)。

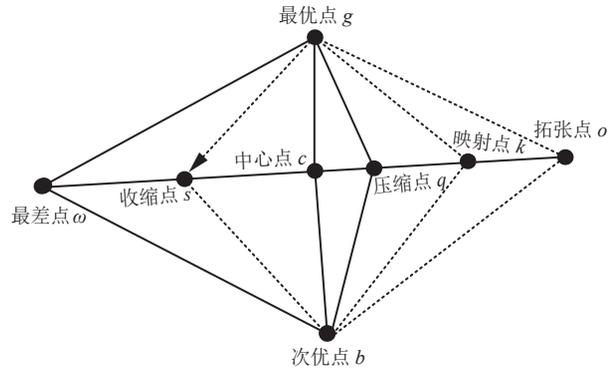


图 3 单纯形法搜索更新点示意图

Fig. 3 Simplex method search for update points

依据搜索更新点位置图,单纯依形算法步骤如下^[22]:

计算最优点 g 、最差点 ω 、次优点 b ,由最优及最差点求解中心点 c 。

1)映射过程。计算映射点 $k = c + \alpha(c - \omega)$, α 为映射系数值,取 1.5。

2)拓张过程。若 $\omega > c$,则计算拓张点 $o = c + \beta(r - c)$, β 为拓张系数,取 3。若 $o > g$,则使用拓张点代替最差点,反之由映射点代替最差点。

3)挤压过程。若 $g > k$,表明此时映射方向错误,则进行向内压缩 $q = c + X(\omega - c)$, X 为挤压系数,取 0.5。若 $q > \omega$,则使用压缩点代替最差点。若 $\omega < k < g$,则进行向外收缩 $s = c - X(\omega - c)$ 。若存在 $s > \omega$,则采用收缩点 s 代替最差点,反之采用映射点替代。

映射过程可以使最差点向所有可行解进行搜寻;拓张过程可以使最优点反向搜索距离最差点更远的可行解。如果当前寻得最优点为极值点,拓张过程可以使该点绕开局部极值处,获取更多可行解;挤压操作可使较差点收缩至更好位置。融合单纯形法可以提高鲸鱼算法的拓张能力与寻优能力,在种群内对局部进行更宽范围的搜索,避免陷入局部最优。

2.4 基于莱维飞行的螺旋参数更新

在原始 WOA 中,气泡螺旋捕食阶段鲸鱼会根据猎物方位进行螺旋位置更新,螺旋参数 l 为 $[-1, 1]$ 之间的随机数,游走范围较小,弱化了算法的全局寻优能力。为解决此问题,结合莱维飞行^[23],采用飞

行步长 L_v 代替螺旋参数 l 。莱维飞行是一种随机步长生成方法, 在随机游走过程中有几率出现跨步行为, 使当前解跳出局部范围, 可以有效规避局部最优^[24]:

$$L_v = \chi \otimes \frac{u}{|v|^{1/\kappa}} \quad (11)$$

$$\partial_u = \left[\frac{\Gamma(1+\kappa) \sin(\kappa\pi/2)}{\Gamma((1+\kappa)/2) 2^{(\kappa-1)/2} \kappa} \right]^{1/\kappa} \quad (12)$$

$$\partial_v = 1 \quad (13)$$

式中: χ 为步长缩放因子; u 、 v 均服从正态分布, $u \sim N(0, \partial_u^2)$, $v \sim N(0, \partial_v^2)$; κ 为 $[0, 2]$ 内的常数, 取 1.5。

引入后气泡螺旋围捕公式为:

$$X(t+1) = D' e^{b \cdot L_v} \cos(2\pi l) + S_1 X_{best}(t) \quad (14)$$

3 MWIWOA-SVM 预测模型

SVM 回归预测受核函数参数 γ 以及惩罚因子 C 的取值影响, 为此, 采用 MWIWOA 对两个关键参数进行寻优。首先, 消除各因素间互相影响的量纲问题, 对采用数据进行归一化处理^[25], 存在 n 个样本 (x_i, y_i) , $i \in [1, n]$, 输入集 $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]$, m 为腐蚀影响因素个数。

$$x_{ik}^* = \frac{x_{ik} - x_{imin}}{x_{imax} - x_{imin}} \quad (15)$$

式中: x_{ik} 为第 i 条数据的第 k 种影响因素; x_{imin} 、 x_{imax} 分别为第 k 种影响因素的最小值、最大值; x_{ik}^* 为数据处理后得到的样本。

对参数进行初始化并对各个参数进行迭代更新, 根据式(6)、式(7)混沌映射反向学习初始化种群, 搜索并计算每个鲸鱼个体适应度 f_i , 并记录当前领导者位置 X_{leader} , 由式(1)、式(8)、式(9)、式(11)更新参数 a 、 A 、 S_1 、 S_2 、 L_v 。进入算法, 判断参数取值, 若 $p < 0.5$ 且 $|A| < 1$, 则进行包围猎物机制; 若 $p < 0.5$ 且 $|A| \geq 1$, 则进行随机搜索机制, 由式(10)对鲸鱼位置进行更新; 若 $p \geq 0.5$, 则进行气泡螺旋捕食机制进行围捕, 结合已优化更新参数并根据式(14)更新鲸鱼位置; 在更新位置基础上根据单纯依形优化位置最差解, 对当前最优领导者个体 X_{leader} 进行更新。直至算法满足迭代条件, 退出循环并输出最优解。

将寻优得到的 γ 、 C 代入 SVM 回归预测模型中, 将归一化的数据按照 42: 8 的比例划分为训练集与测试集。将数据分组作为输入量代入, 使用 MATLAB 运行该模型, 输出海底管道内腐蚀速率预测值(图 4)。

为对比不同模型的预测性能, 采用平均绝对百分比误差 MAPE、均方根误差 RMSE、决定系数 R^2 及拟合度 D_f 验证评估模型精度与优劣性^[26]。

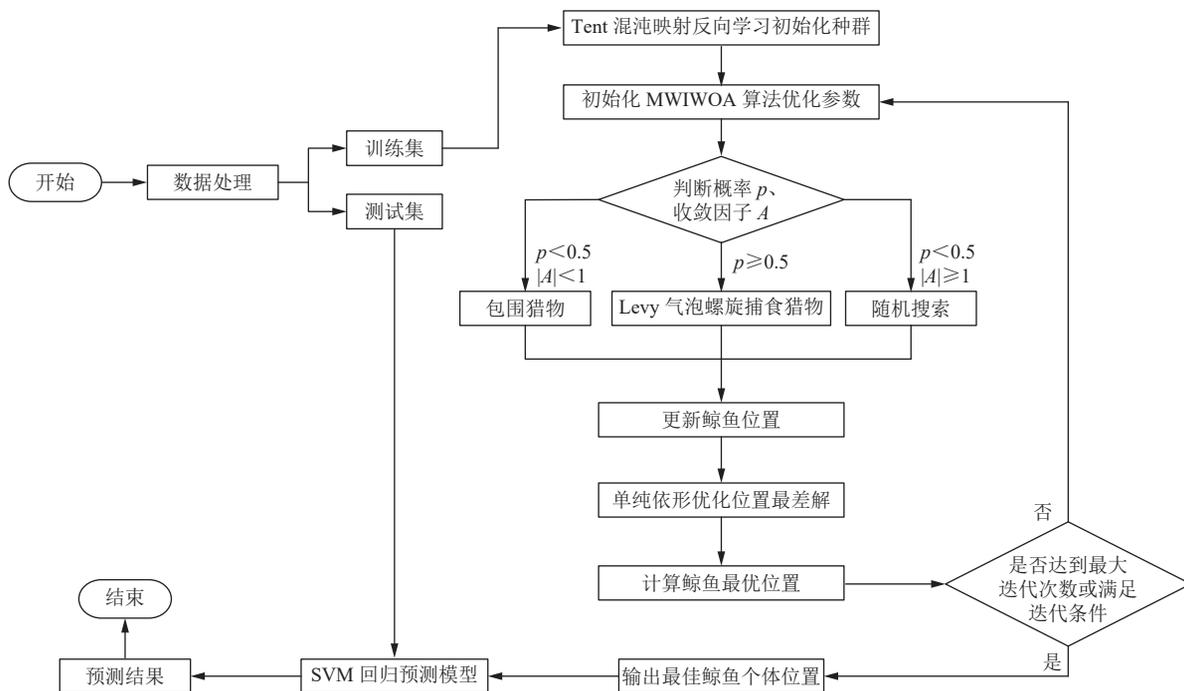


图 4 基于 MWIWOA-SVM 模型的海底管道内腐蚀速率预测流程图

Fig. 4 Flowchart for predicting internal corrosion rates in submarine pipelines using the MWIWOA-SVM model

4 实例分析

4.1 数据来源

基于中海油开发油田建设工程公司对 SP74-FPSO 管道段内管腐蚀情况的检查结果以及海洋管

道网普查项目提供的管道数据,整理出 50 组适配于管道内腐蚀分析研究的数据。包括温度 X_1 、系统压力 X_2 、 CO_2 分压 X_3 、pH 值 X_4 、介质流速 X_5 、 Cl^- 质量分数 X_6 、 CO_2 质量浓度 X_7 、 HCO_3^- 质量分数 X_8 、含水率 X_9 、内腐蚀速率 X_0 (表 1)。

表 1 内腐蚀速率原始数据表
Table 1 Original data of internal corrosion rate

样本序号	$X_1/^\circ\text{C}$	X_2/MPa	X_3/MPa	X_4	$X_5/(\text{m}\cdot\text{s}^{-1})$	$X_6/(\text{mg}\cdot\text{L}^{-1})$	$X_7/(\text{mg}\cdot\text{L}^{-1})$	$X_8/(\text{mg}\cdot\text{L}^{-1})$	X_9	$X_0/(\text{mm}\cdot\text{a}^{-1})$
1	63.9	2.43	0.032 7	5.61	0.651	7 680	26.2	60.5	146%	2.838 5
2	62.4	2.11	0.031 9	5.22	0.657	6 940	24.6	57.3	138%	2.632 5
...
49	54.4	2.31	0.032 6	5.37	0.513	6 080	15.4	51.4	136%	2.266 8
50	56.2	1.73	0.031 2	5.42	0.494	6 510	15.9	53.6	131%	2.273 1

4.2 MWIWOA-SVM 模型训练

选取 $X_1 \sim X_9$ 作为海底长输管道内腐蚀速率影响因素特征指标,以 X_0 作为海底长输管道内腐蚀速率特征指标。利用 MWIWOA 对 SVM 模型中的参数寻优,选取未优化 WOA 寻优的 SVM 模型作为对照模型。随机选取 42 组数据作为样本训练集,剩余的 8 组作为测试集,用于检验模型精度与准确性。采用影响因素特征指标训练集对模型进行训练,对比两模型使用同一数据集达到最佳收敛所需时间与最优收敛度,采用均方根误差作为适应度函数。初始鲸鱼种群数量设为 50,最大迭代次数为 200(图 5)。可见寻优前期,MWIWOA 在算法迭代至 23 代时达到最优收敛;而 WOA 在算法迭代至 51 代时达到最优收敛。MWIWOA 模型较 WOA 模型优先达到收敛,且 RMSE 更小,可见 MWIWOA 模型效率更好,跳脱局部最优能力更强,能取得更好的预测结果;同时,在寻优后

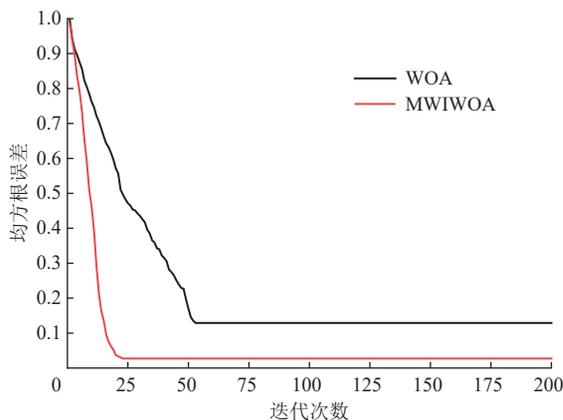


图 5 WOA 与 MWIWOA 模型均方根误差随迭代次数变化曲线
Fig. 5 RMSE variation curves with iteration count for WOA and MWIWOA models

期,MWIWOA 模型的抗停滞性能更优,最终 RMSE 仅为 0.027 1,寻优精度更佳。

4.3 预测精度验证

为检验 MWIWOA-SVM 模型的预测精度,选用 WOA-SVM、PSO-SVM、SVM 这 3 种模型与之对比(图 6),可见 MWIWOA-SVM 模型预测数据更接近真实值,拟合度为 99.48%, $R^2=98.37\%$,较其他模型预测精度更高。

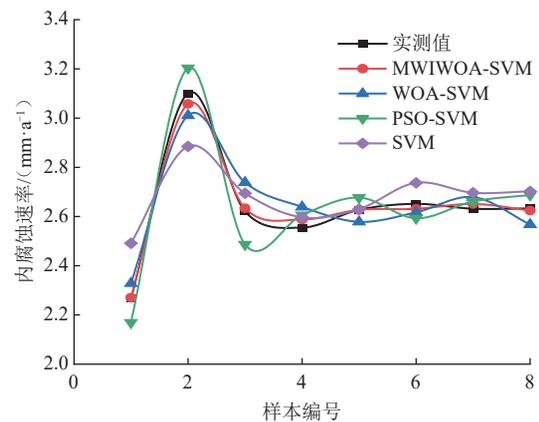


图 6 不同内腐蚀速率预测模型预测结果对比图
Fig. 6 Comparison of prediction results across various internal corrosion rate prediction models

为对比模型预测内腐蚀速率数值与真实值之间的误差波动,需要对每个节点的误差数据进行计算分析。相对误差可以更直观地表现节点预测数据与真实值之间的误差波动范围及预测准确性。计算测试集数据每个样本节点的相对误差(图 7),可见 MWIWOA-SVM 模型测试集预测值的相对误差波动更平稳,预测更为精确。

对比不同模型的内腐蚀速率预测相对误差

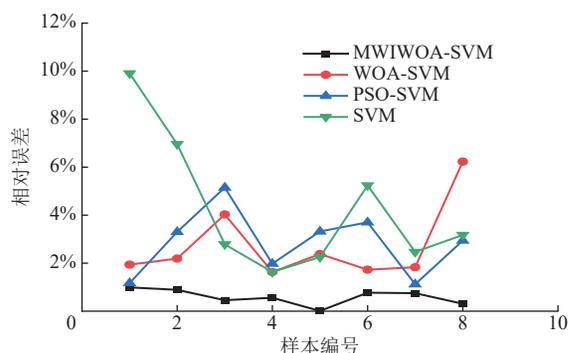


图 7 不同内腐蚀速率预测模型相对误差对比图
Fig. 7 Comparison of relative errors across various internal corrosion rate prediction models

(表 2), 可见 MWIWOA-SVM 模型的最大相对误差出现在第 1 个点, 为 0.99%, 其余预测点相对误差均优于其余模型。可见, MWIWOA-SVM 模型在海洋长输管道内腐蚀速率预测方面具有更好的性能。

对比 4 种模型的预测性能指标(表 3), 可见 SVM 模型的 MAPE 值为 11.24%, MWIWOA-SVM 模型的 MAPE 值为 1.48%, 较原模型精度有很大提升。各项性能中, MWIWOA-SVM 模型均取得最优数据, MAPE 下降明显。综上, 在海底长输管道内腐蚀速率预测方面, MWIWOA-SVM 的效果最优。

表 2 各模型内腐蚀速率预测相对误差对比表
Table 2 Comparison of relative errors in internal corrosion rate predictions across various models

实测值	腐蚀速率/(mm·a ⁻¹)				相对误差			
	SVM	PSO-SVM	WOA-SVM	MWIWOA-SVM	SVM	PSO-SVM	WOA-SVM	MWIWOA-SVM
2.266 8	2.491 1	2.168 8	2.328 5	2.270 4	9.910%	1.17%	1.94%	0.99%
3.100 7	2.884 9	3.203 1	3.010 7	3.057 5	6.960%	3.30%	2.19%	0.89%
2.621 5	2.694 4	2.486 4	2.738 6	2.633 7	2.784%	5.15%	4.03%	0.46%
2.554 9	2.596 4	2.605 5	2.639 0	2.588 0	1.634%	1.98%	1.63%	0.56%
2.627 1	2.630 4	2.676 5	2.578 3	2.626 8	2.254%	3.32%	2.38%	0.01%
2.651 3	2.736 7	2.592 8	2.616 7	2.631 0	5.240%	3.70%	1.73%	0.77%
2.631 3	2.696 4	2.660 7	2.678 4	2.651 0	2.470%	1.12%	1.83%	0.75%
2.632 5	2.702 1	2.687 3	2.567 6	2.624 5	3.176%	2.94%	6.23%	0.31%

表 3 各模型预测性能指标对比表
Table 3 Comparison of prediction performance index parameters across multiple models

模型	RMSE	MAPE	D _F	R ²
SVM	1.127 8	11.24%	0.903 3	0.701 1
PSO-SVM	0.565 6	5.17%	0.951 4	0.844 1
WOA-SVM	0.129 1	8.05%	0.961 8	0.917 5
MWIWOA-SVM	0.027 1	1.48%	0.994 8	0.983 7

5 结论

针对 SVM 模型存在的收敛速度慢、精度较低、易受人为设定参数影响等缺陷, 构建 MWIWOA-SVM 海洋长输管道内腐蚀速率模型, 对模型进行实例验证, 得到以下结论:

1) 引入混沌映射反向学习、非线性收敛因子和自适应权重、单纯形法、Levy 飞行步长 4 种改进策略, 提高了算法整体性能。基于多途径改进后鲸鱼算法优化 SVM, 其收敛速度更快, 解决了全局和局部搜索失衡的问题, 跳脱出局部最优解的情况, 预测准确度更高。

2) 与 SVM、WOA-SVM、PSO-SVM 模型进行对比, MWIWOA-SVM 模型各项预测性能指标均为最优。其 MAPE、RMSE、R²、D_F 的值分别为 1.48%、0.027、98.37%、99.48%, 预测结果更符合真实数据, 在海底管道内腐蚀预测性能方面更优。

3) MWIWOA-SVM 海底长输管道内腐蚀速率预测模型具备良好的预测性能, 但在现实应用中管道腐蚀往往面临更为复杂的情况, 因此后续研究可构建管道腐蚀数据库, 利用大样本数据进一步对模型进行拟合。

参考文献:

[1] 徐学武. 海底油气管道内腐蚀分析与防护[J]. 腐蚀与防护, 2014, 35(5): 500-504.
XU X W. Analysis and protection of internal corrosion for submarine pipelines of oil and gas[J]. Corrosion & Protection, 2014, 35(5): 500-504.

[2] COLE I S, MARNEY D. The science of pipe corrosion: a review of the literature on the corrosion of ferrous metals in soils[J]. Corrosion Science, 2012, 56: 5-16. DOI: 10.1016/j.corsci.2011.12.001.

[3] 骆正山, 宋莹莹, 毕傲睿. 基于 GRA-RFR 的油气集输管道内腐

- 蚀速率预测[J]. 材料保护, 2020, 53(3): 95-100. DOI: [10.16577/j.cnki.42-1215/tb.2020.03.017](https://doi.org/10.16577/j.cnki.42-1215/tb.2020.03.017).
- LUO Z S, SONG Y Y, BI A R. Prediction model of internal corrosion rate in oil and gas gathering pipelines based on GRA-RFR[J]. Materials Protection, 2020, 53(3): 95-100.
- [4] 张梁, 高源, 杨光, 李民强. BP神经网络模型的改进及其在海底管道外腐蚀速率预测中的应用[J]. 安全与环境学报, 2023, 23(11): 3882-3888. DOI: [10.13637/j.issn.1009-6094.2022.1608](https://doi.org/10.13637/j.issn.1009-6094.2022.1608).
- ZHANG L, GAO Y, YANG G, LI M Q. Improvement of the BP neural network model and its application in the prediction of the external corrosion rate of submarine pipeline[J]. Journal of Safety and Environment, 2023, 23(11): 3882-3888.
- [5] 肖荣鹤, 王栋, 王勤学. 基于ASO-BP神经网络的海底油气管道腐蚀速率预测[J]. 化学工业与工程, 2022, 39(6): 109-116. DOI: [10.13353/j.issn.1004.9533.20216004](https://doi.org/10.13353/j.issn.1004.9533.20216004).
- XIAO R G, WANG D, WANG Q X. Prediction of corrosion rate of submarine oil and gas pipelines based on ASO-BP neural network[J]. Chemical Industry and Engineering, 2022, 39(6): 109-116.
- [6] ZHI Y J, FU D M, YANG T, ZHANG D W, LI X G, PEI Z B. Long-term prediction on atmospheric corrosion data series of carbon steel in China based on NGBM(1, 1) model and genetic algorithm[J]. Anti-Corrosion Methods and Materials, 2019, 66(4): 403-411. DOI: [10.1108/ACMM-11-2017-1858](https://doi.org/10.1108/ACMM-11-2017-1858).
- [7] 贾海韵, 胡丽华, 李夏侨, 曲志豪, 王竹, 常炜, 等. 基于核主成分分析算法的海底管道内腐蚀风险预测[J]. 腐蚀与防护, 2023, 44(3): 82-87. DOI: [10.11973/fsyfh-202303012](https://doi.org/10.11973/fsyfh-202303012).
- JIA H Y, HU L H, LI X Q, QU Z H, WANG Z, CHANG W, et al. Internal corrosion risk prediction of submarine pipeline based on kernel principal component analysis[J]. Corrosion and Protection, 2023, 44(3): 82-87.
- [8] TIAN L, LUO Y. A study on the prediction of inherent deformation in fillet-welded joint using support vector machine and genetic optimization algorithm[J]. Journal of Intelligent Manufacturing, 2020, 31(3): 575-596. DOI: [10.1007/s10845-019-01469-w](https://doi.org/10.1007/s10845-019-01469-w).
- [9] HATAMI S, GHADERI-ARDAKANI A, NIKNEJAD-KHOMAMI M, KARIMI-MALEKABADI F, RASAEI M R, MOHAMMADI A H. On the prediction of CO₂ corrosion in petroleum industry[J]. The Journal of Supercritical Fluids, 2016, 117: 108-112. DOI: [10.1016/j.supflu.2016.05.047](https://doi.org/10.1016/j.supflu.2016.05.047).
- [10] 梁晶晶, 谢波, 刘延庆, 刘志娟, 郭自强, 任春燕, 等. 基于KPCA-GWO-SVM的埋地管道土壤腐蚀速率预测[J]. 油气储运, 2021, 40(8): 938-944. DOI: [10.6047/j.issn.1000-8241.2021.08.016](https://doi.org/10.6047/j.issn.1000-8241.2021.08.016).
- LIANG C J, XIE B, LIU Y Q, LIU Z J, GUO Z Q, REN C Y, et al. Prediction of soil corrosion rate of buried pipeline based on KPCA-GWO-SVM[J]. Oil & Gas Storage and Transportation, 2021, 40(8): 938-944.
- [11] 王盼锋, 王寿喜, 马钢, 全青. 基于PCA-PSO-SVM模型的海底多相流管道内腐蚀速率预测[J]. 安全与环境工程, 2020, 27(2): 183-189. DOI: [10.13578/j.cnki.issn.1671-1556.2020.02.025](https://doi.org/10.13578/j.cnki.issn.1671-1556.2020.02.025).
- WANG P F, WANG S X, MA G, QUAN Q. Prediction of internal corrosion rate of submarine multiphase flow pipelines based on PCA-PSO-SVM model[J]. Safety and Environmental Engineering, 2020, 27(2): 183-189.
- [12] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67. DOI: [10.1016/j.advengsoft.2016.01.008](https://doi.org/10.1016/j.advengsoft.2016.01.008).
- [13] 师国东, 胡明茂, 宫爱红, 龚青山, 郭庆贺, 谭浩. 基于XGBoost-MSIWOA-LSTM的车辆油耗优化预测模型[J/OL]. 计算机集成制造系统: 1-24[2024-09-11]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20230724.1508.002.html>.
- SHI G D, HU M M, GONG A H, GONG Q S, GUO Q H, TAN H. Optimal prediction model of vehicle fuel consumption based on XGBoost-MSIWOA-LSTM[J/OL]. Computer Integrated Manufacturing Systems: 1-24[2024-09-11]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20230724.1508.002.html>.
- [14] VAPNIK V N. 统计学习理论[M]. 许建华, 张学工, 译. 北京: 电子工业出版社, 2004: 1-559.
- VAPNIK V N. Statistical learning theory[M]. XU J H, ZHANG X G, translated. Beijing: Publishing House of Electronics Industry, 2004: 1-559.
- [15] 刘昆. 粒子群算法优化支持向量机的网络流量混沌预测[J]. 现代电子技术, 2019, 42(2): 120-123. DOI: [10.16652/j.issn.1004-373x.2019.02.028](https://doi.org/10.16652/j.issn.1004-373x.2019.02.028).
- LIU K. Chaotic prediction of network traffic based on particle swarm algorithm optimization and support vector machine[J]. Modern Electronics Technique, 2019, 42(2): 120-123.
- [16] 梁文娟, 李雪艳. 基于ARIMA、LS-SVM和BP神经网络组合模型的航空运输飞行事故征候预测[J]. 安全与环境工程, 2018, 25(1): 130-136. DOI: [10.13578/j.cnki.issn.1671-1556.2018.01.023](https://doi.org/10.13578/j.cnki.issn.1671-1556.2018.01.023).
- LIANG W J, LI X Y. Flight incidents prediction of air transportation based on the combined model of ARIMA, LS-SVM

- and BPNN[J]. *Safety and Environmental Engineering*, 2018, 25(1): 130–136.
- [17] 单梁, 强浩, 李军, 王执铨. 基于 Tent 映射的混沌优化算法[J]. *控制与决策*, 2005, 20(2): 179–182. DOI: [10.13195/j.cd.2005.02.60.shanl.013](https://doi.org/10.13195/j.cd.2005.02.60.shanl.013).
- SHAN L, QIANG H, LI J, WANG Z Q. Chaotic optimization algorithm based on Tent map[J]. *Control and Decision*, 2005, 20(2): 179–182.
- [18] TIZHOOSH H R. Opposition-Based learning: a new scheme for machine intelligence[C]. Vienna: International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06), 2005: 695–701.
- [19] 林娟, 钟一文, 马森林. 改进的反向蛙跳算法求解函数优化问题[J]. *计算机应用研究*, 2013, 30(3): 760–763. DOI: [10.3969/j.issn.1001-3695.2013.03.030](https://doi.org/10.3969/j.issn.1001-3695.2013.03.030).
- LIN J, ZHONG Y W, MA S L. Improved opposition-based shuffled frog leaping algorithm for function optimization problems[J]. *Application Research of Computers*, 2013, 30(3): 760–763.
- [20] RANA N, ABD LATIFF M S, ABDULHAMID S M, MISRA S. A hybrid whale optimization algorithm with differential evolution optimization for multi-objective virtual machine scheduling in cloud computing[J]. *Engineering Optimization*, 2022, 54(12): 1999–2016. DOI: [10.1080/0305215X.2021.1969560](https://doi.org/10.1080/0305215X.2021.1969560).
- [21] 任小康, 郝瑞芝, 孙正兴, 史变霞. 基于单纯形法的量子粒子群优化算法[J]. *微电子学与计算机*, 2010, 27(1): 154–157. DOI: [10.19304/j.cnki.issn1000-7180.2010.01.041](https://doi.org/10.19304/j.cnki.issn1000-7180.2010.01.041).
- REN X K, HAO R Z, SUN Z X, SHI B X. Quantum_ behaved particle swarm optimization algorithm based on simplex method[J]. *Microelectronics & Computer*, 2010, 27(1): 154–157.
- [22] 张潮, 冯锋. 混沌策略和单纯形法改进的鲸鱼优化算法[J]. *中国科技论文*, 2020, 15(3): 293–299. DOI: [10.3969/j.issn.2095-2783.2020.03.007](https://doi.org/10.3969/j.issn.2095-2783.2020.03.007).
- ZHANG C, FENG F. Whale optimization algorithm based on chaotic strategy and simplex method[J]. *China Sciencepaper*, 2020, 15(3): 293–299.
- [23] 王秋萍, 丁成, 王晓峰. 一种基于改进 KH 与 KHM 聚类的混合数据聚类算法[J]. *控制与决策*, 2020, 35(10): 2449–2458. DOI: [10.13195/j.kzyjc.2019.0086](https://doi.org/10.13195/j.kzyjc.2019.0086).
- WANG Q P, DING C, WANG X F. A hybrid data clustering algorithm based on improved krill herd algorithm and KHM clustering[J]. *Control and Decision*, 2020, 35(10): 2449–2458.
- [24] 雍欣, 高岳林, 赫亚华, 王惠敏. 多策略融合的改进萤火虫算法[J]. *计算机应用*, 2022, 42(12): 3847–3855. DOI: [10.11772/j.issn.1001-9081.2021101830](https://doi.org/10.11772/j.issn.1001-9081.2021101830).
- YONG X, GAO Y L, HE Y H, WANG H M. Improved firefly algorithm based on multi-strategy fusion[J]. *Journal of Computer Applications*, 2022, 42(12): 3847–3855.
- [25] 骆正山, 马昌宝, 王小完. 基于 RS-MSWOA-LSSVM 的油气管道失效压力预测[J]. *安全与环境工程*, 2022, 29(4): 163–171. DOI: [10.13578/j.cnki.issn.1671-1556.20211155](https://doi.org/10.13578/j.cnki.issn.1671-1556.20211155).
- LUO Z S, MA C B, WANG X W. Prediction of oil and gas pipeline failure pressure based on RS-MSWOA-LSSVM[J]. *Safety and Environmental Engineering*, 2022, 29(4): 163–171.
- [26] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning[M]. Cambridge: MIT Press, 2005: 79–102.

(编辑: 张腾)

基金项目: 国家自然科学基金资助项目“在役海底油气输送管道风险评估与管理研究”, 41877527.

作者简介: 骆正山, 男, 1969 年生, 教授, 2009 年博士毕业于西安建筑科技大学结构工程专业, 现主要从事油气管道的腐蚀防护、风险评估与建模等方面的研究工作。地址: 陕西省西安市碑林区雁塔路中段 13 号, 710055。电话: 18591980812。Email: luozhengshan@163.com

通信作者: 吕海鹏, 男, 2000 年生, 在读硕士生, 2022 年毕业于河北科技师范学院工程管理专业, 现主要从事油气管道输送技术方面的研究工作。地址: 陕西省西安市鄠邑区草寺东路, 710055。电话: 13393388838。Email: 1031456444@qq.com

• Received: 2024-09-15

• Revised: 2024-10-21

• Online: 2025-01-23

