

基于 LASSO-WOA-LSSVM 的 海洋管线外腐蚀速率预测

骆正山, 秦越, 张新生, 毕傲睿

(西安建筑科技大学 管理学院, 西安 710055)

摘 要: **目的** 构建海洋管线外腐蚀速率预测模型, 提高海底油气管线外腐蚀速率预测的准确性。**方法** 建立基于套索 (LASSO) 回归和鲸鱼优化算法 (WOA) 的最小二乘支持向量机 (LSSVM) 腐蚀速率预测模型, 采用 LASSO 回归方法对指标进行筛选, 提取海洋管线腐蚀的主要影响因素。应用最小二乘支持向量机算法建立海洋管线外腐蚀速率预测模型, 并使用鲸鱼优化算法对模型参数进行优化, 避免了参数取值对模型回归性能的影响。以海洋挂片实验为例, 通过 MATLAB 进行模拟仿真, 分析验证模型预测结果, 并将预测结果与其他模型进行对比分析。**结果** LASSO 回归算法筛选得到影响腐蚀速率的主要因素为: 温度、溶解氧含量、pH 值。采用 WOA-LSSVM 模型所预测的结果与实际值较为吻合, 其平均相对误差为 2.23%, 均方根误差 (RMSE) 为 0.3248, 决定系数 R^2 达到 0.9708, 均优于其他两种模型。**结论** 基于 LASSO 回归和鲸鱼优化算法的最小二乘支持向量机预测模型具有更优的泛化能力和预测精度, 为海底管道腐蚀研究工作提供了新思路, 也为海洋油气输送系统的结构安全与风险防范提供了参考。

关键词: 海洋管线; 外腐蚀速率预测模型; LASSO 回归方法; 鲸鱼优化算法 (WOA); 最小二乘支持向量机 (LSSVM)

中图分类号: TG172 文献标识码: A 文章编号: 1001-3660(2021)05-0245-08

DOI: 10.16490/j.cnki.issn.1001-3660.2021.05.027

Prediction of External Corrosion Rate of Marine Pipelines Based on LASSO-WOA-LSSVM

LUO Zheng-shan, QIN Yue, ZHANG Xin-sheng, BI Ao-rui

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

ABSTRACT: The paper aims to construct a prediction model for the external corrosion rate of marine pipelines and improve the accuracy of prediction for the corrosion rate of offshore pipelines, the least square support vector machine (LSSVM) corrosion

收稿日期: 2020-03-28; 修订日期: 2020-06-04

Received: 2020-03-28; Revised: 2020-06-04

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

Fund: Supported by National Natural Science Foundation of China (41877527) and Shaanxi Social Science Foundation Subsidized Projects (2018S34)

作者简介: 骆正山 (1969—), 男, 博士, 教授, 主要研究方向为管理科学与工程、信息管理与信息系统、油气管道风险评估等。邮箱: luozhengshan@163.com

Biography: LUO Zheng-shan (1969—), Male, Doctor, Professor, Research focus: mainly engaged in teaching and scientific research in management science and engineering, information management and information system, oil and gas pipeline risk assessment and other disciplines. E-mail: luozhengshan@163.com

引文格式: 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.

rate prediction model based on LASSO (LASSO) regression algorithm and whale optimization algorithm (WOA) was established. The index was screened by LASSO regression method to extract the main influencing factors of marine pipeline corrosion. The least square support vector machine algorithm is used to establish a prediction model for the corrosion rate of submarine pipelines, and the whale optimization algorithm is used to optimize the model parameters to avoid the influence of parameter values on the regression performance of the model. Based on the experiment of real sea hanging film, the simulation is carried out through MATLAB, and the prediction results of the model are analyzed and verified, and the prediction results are compared with other models. The main factors obtained by LASSO regression algorithm are temperature, dissolved oxygen content and pH value. The prediction results of the adopted WOA-LSSVM model are in good agreement with the actual values. The average relative error is 2.23%, the root mean square error (RMSE) is 0.3248, and the coefficient of determination R^2 reaches 0.9708, which are better than the other two models. The prediction model of the least square support vector machine based on LASSO regression and whale optimization algorithm has better generalization ability and prediction accuracy, which provides a new idea for the research of submarine pipeline corrosion, and also provides a reference for the structural safety and risk prevention of marine oil and gas transportation system.

KEY WORDS: marine pipeline; external corrosion rate prediction model; LASSO regression method; whale optimization algorithm (WOA); least squares support vector machine (LSSVM)

在役海底油气管线通常处于复杂恶劣的海洋环境中,管段经常会遭受严重腐蚀,从而造成管段结构破坏与经济损失^[1]。对于陆上管道,可通过各种检测方法了解管道的腐蚀状况,但对海洋环境中管道的检测相对困难,利用机器学习算法预测管道腐蚀速率是一种较为理想的方法^[2-3]。因此,研究海底管道的腐蚀机理和规律,建立准确、有效的预测模型具有十分重要的现实意义。

目前,国内学者对海底油气管道的腐蚀行为进行了大量研究。骆正山等^[4]建立了海底油气管道腐蚀速率预测的 Frechet 分布模型,该模型只预测了油气管道的腐蚀深度和管道寿命,未表明预测误差。同时,骆正山等^[5]建立了基于误差补偿的 GM-RBF 海底输油管道腐蚀速率的预测模型,该研究将 GM 模型用于预测腐蚀速率,但模型预测误差较大。王庆锋^[6]等基于 GM(1,1)模型建立了无偏灰色 GM(1,1)模型,构建的无偏灰色马尔可夫链组合模型可对管线腐蚀剩余寿命进行预测。但传统单维灰色模型分析法以时间序列为轴线,未能表明其他环境因素的相互联系及其对响应变量的具体影响。邓志安等^[7]建立了 GRA-FNN 模型,对海洋管线腐蚀速率进行了预测,但灰色关联分析中的各指标均需人为确定,主观性强。李响等^[8]构建了遗传算法 SVM 模型,对海洋环境腐蚀速率进行了预测,解决了 BP 神经网络等智能算法需要大量训练样本的问题,但 SVM 参数选取较为复杂,收敛速度不够快。以上的研究均存在诸如影响因素考虑欠全面、算法迭代速度较慢和预测精度不够高等问题。

鉴于此,本文提出了一种将套索回归(LASSO)、鲸鱼优化算法(WOA)和最小二乘支持向量机(LSSVM)有机结合的海底管道腐蚀预测新方法。采用 LASSO 回归,约简样本指标,提取主要变量,并使用 WOA 对 LSSVM 的核函数宽度和惩罚因子两

个参数进行了优化,建立了 LASSO-WOA-LSSVM 的海底管道腐蚀速率预测模型,以海洋挂片实验数据为例进行实证研究,通过指标和对比,对模型性能进行验证和分析。

1 LASSO 变量选择

影响海底管道腐蚀速率的因素众多,其主要影响因素为以下五项:海水温度^[9]、溶解氧含量^[10]、盐度^[11]、pH 值^[12]和氧化还原电位^[13]。

在建立腐蚀回归模型时,若将某些对因变量影响较小的影响因子选入模型,会降低模型的预测精度^[14]。故在腐蚀失效预测前,应先对海洋管线的各腐蚀因素进行分析,筛选出关键因素。

LASSO (Least Absolute Shrinkage and Selection Operator) 即最小绝对值压缩选择算法^[15-17],是 Tishirani 提出的一种非负干扰激励的变量选择方法。该方法通过构造惩罚函数来压缩变量系数,使压缩后某些绝对值较小的系数直接变为零,这些变量将被删除,从而同时达到降维与参数选择的目的。

假设给定数据集 (X, Y) , X 是自变量向量, $X_i (i=1, 2, \dots, n)$, Y 是因变量向量, $Y_i (i=1, 2, \dots, n)$, 系数向量为 $\beta(\beta_1, \beta_2, \dots, \beta_m)$ 。令 $\beta=(\beta_1, \beta_2, \dots, \beta_m)^T$, 则 LASSO 的估计量为:

$$(\hat{\alpha}, \hat{\beta}) = \arg \min_{\alpha, \beta} \left\{ \sum_{i=1}^n \left(Y_i - \alpha - \sum_{j=1}^m \beta_j X_{ij} \right)^2 \right\},$$

$$s.t. \sum_{j=1}^m |\beta_j| \leq t \quad (1)$$

$t \geq 0$ 时为调整参数,对于任意一个 t , 都有一个的估计量 $\hat{a} = \bar{y}a$ 。在无一般性损失的条件下,我们假定 $\bar{y} = 0$, 以上问题可用惩罚函数的形式表示:

$$\hat{\beta} = \arg \min_{\beta} \left\{ \sum_i \left[\left(Y_i - \sum_{j=1}^m \beta_j X_{ij} \right)^2 + \lambda \sum_{j=1}^m |\beta_j| \right] \right\} \quad (2)$$

式中, X_i 是第 i 组自变量, Y_i 是对应于 X_i 的因变量的值, X_i 经标准化后得到 X_{ij} , β_j 是回归系数, n 为组数, t 为非负调整参数。 λ 是正则化参数, λ 越小, 惩罚项的力度越小, 模型保留变量越多; λ 越大, 惩罚项的力度越大, 模型保留变量越少。

2 基于鲸鱼优化算法的最小二乘支持向量机模型

2.1 最小二乘支持向量机

最小二乘支持向量机 (LSSVM) [18-19] 是一种基于传统 SVM 算法的改进算法, 在对偶空间中, LSSVM 通过用等式代替不等式约束, 并将线性最小二乘准则应用于损失函数优化, 实现了凸二次规划问题向线性方程组问题的求解转变, 提高了收敛速度 [20]。LSSVM 的实现过程如下:

(1) 给定训练集 $D = \{(x_i, y_i) | i=1, 2, \dots, n\}$, $x_i \in R^n$ 是第 i 个输入样本, $y_i \in \{-1, +1\}$ 是输出变量组。

(2) 在高维空间中构造回归函数:

$$y(x) = \omega \cdot \phi(x) + b \quad (3)$$

ω 为可调权向量, $\phi(x)$ 是非线性核映射函数, b 为偏差参数。

(3) 根据结构风险最小准则, 最优 ω 和 b 可经下述函数最小化得到:

$$\min_{(\omega, b, \xi)} J(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + \frac{C}{2} \sum_{i=1}^n \xi_i^2 \quad (4)$$

s.t. $y_i = \omega \cdot \phi(x_i) + b + \xi_i$

其中, C 是平衡训练误差与模型适应度的正则化参数, ξ_i 是随机误差。

(4) 为解决 LSSVM 的优化问题, 构造如下拉格朗日函数:

$$L(\omega, b, \xi, \alpha) = J(\omega, \xi) - \sum_{i=1}^n \alpha_i (\omega \cdot \phi(x_i) + b + \xi_i - y_i) \quad (5)$$

此处的 α_i 是 Lagrange 乘子。根据 KKT (Karush-Kuhn-Tucker) 条件, 分别求解 $L(\omega, b, \xi, \alpha)$ 对 ω 、 b 、 ξ 、 α 的偏微分, 可得:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \Rightarrow \omega - \sum_{i=1}^n \alpha_i \phi(x_i) = 0 \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C \xi_i - \alpha_i = 0 \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow \omega \cdot \phi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (6)$$

(5) 消除 ω 和 ξ_i , 并以矩阵形式表达:

$$\begin{bmatrix} 0 & e^T \\ e & \Omega_{ij} + C^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (7)$$

式中, $e = [1, \dots, 1]^T$, $y = [y_1, \dots, y_n]^T$, $\alpha = [\alpha_1, \dots, \alpha_n]^T$, $\Omega_{ij} = \phi(x_i) \cdot \phi(x_j) = k(x_i, x_j)$, 其中, $k(x_i, x_j)$ 是核函数矩阵。本文采用 RBF (径向基) 核函数, 其表达如下:

$$k(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{\sigma^2} \right) \quad (8)$$

(6) 最后, 在求解优化问题后, 得到函数估计的线性模型:

$$y = \sum_{i=1}^n \alpha_i k(x_i, x_j) + b \quad (9)$$

2.2 WOA-LSSVM 模型构建

鲸鱼优化算法 (WOA) 是澳大利亚学者 Seyedali Mirjalili 于 2016 年提出的一种新的元启发式算法 [21-24]。在发现猎物后, 座头鲸先潜入猎物的底部, 然后沿着圆圈形路径形成独特的气泡, 如图 1 所示。与此同时, 座头鲸从上游到达海面, 通过气泡将猎物围在较小的范围内吞食。WOA 的工作分为以下三个部分: 收缩包围、气泡网狩猎和搜索猎物。

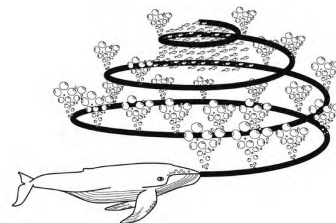


图 1 座头鲸螺旋气泡攻击捕猎行为示意

Fig.1 Spiral bubble attack hunting behavior of humpback whales

在收缩包围阶段, 座头鲸首先会对猎物进行环绕式包围, 该过程可用以下方程描述:

$$D = |CX^*(t) - X(t)| \quad (10)$$

$$X(t+1) = X^*(t) - AD \quad (11)$$

式中, t 为迭代的次数, $X^*(t)$ 为当前鲸鱼的最优位置向量, $X(t)$ 为当前鲸鱼的位置向量, $X(t+1)$ 代表迭代后下一次的目标位置向量, A 、 C 为系数向量, 定义如式(12)、(13)。

$$A = 2ar - a \quad (12)$$

$$C = 2r \quad (13)$$

式中, r 是区间 $[0, 1]$ 内的随机向量, a 值由 2 线性减小至 0。

其次是开发阶段, 该过程实现了收缩包围机制和螺旋更新位置机制, 其数学模型如下: (1) 收缩包围机制, 在该过程中, A 是在 $[a, -a]$ 之间的某随机数, 其值随迭代过程由 2 减小至 0。 (2) 螺旋更新位置机制, 在该机制中, 座头鲸以螺旋状运动方式接近猎物, 该过程的模拟方程如式(14)所示。

$$X(t+1) = D'e^{bl} \cos(2\pi l) + X^*(t) \quad (14)$$

式中, $D' = |X^*(t) - X(t)|$, 代表鲸鱼与当前最优位置间的距离, 常数 b 表征螺旋线的形状, l 是一个在 $[-1, 1]$ 中的随机数。

座头鲸在进行捕猎时, 按照 50% 的概率实施以上两种捕食策略, 其过程如下式所示:

$$X(t+1) = \begin{cases} X^*(t) - AD & p < 0.5 \\ X^*(t) + D'e^{bl} \cos(2\pi l) & p \geq 0.5 \end{cases} \quad (15)$$

其中, p 代表 $[0, 1]$ 之间的随机变量, a 值会随着鲸鱼靠近猎物而减小。若 $|A| < 1$, 鲸鱼将进攻猎物; 若 $|A| > 1$, 鲸鱼将会放弃猎物并重新进行搜寻。

最后是探索阶段。设定随机值 $|A| \geq 1$, 该阶段的数学模型如下:

$$D = |CX_{\text{rand}} - X(t)| \quad (16)$$

$$X(t+1) = X_{\text{rand}} - AD \quad (17)$$

其中, X_{rand} 是所在种群中的随机代理位置向量。在 LSSVM 模型中, 模型预测性能受惩罚因子 C

和核函数宽度 σ 两个参数的影响较大, 故本文采用 WOA 对参数进行优化, 以提高模型的回归性能。具体过程描述如下。

首先对样本集进行归一化, 并设定初始参数, 即对运行过程中 4 个参数的初值进行设置, 分别是鲸鱼种群规模、最大迭代次数 T_{max} 、鲸鱼种群位置的上限与下限。其次, 对种群位置进行初始化, 定义适应度函数, 即将预测值与实际值的均方差作为适应度函数, 并对个体适应度进行计算, 选择出当前最优适应度个体, 设置该个体的位置为当前最优。若 $t < T_{\text{max}}$, 则对 A 、 a 、 C 、 l 、 p 进行更新。当 $p < 0.5$ 时, 若 $|A| \geq 1$, 按照式 (17) 对个体位置进行更新, 若 $|A| < 1$, 则按照式 (11) 更新位置; 当 $p \geq 0.5$ 时, 用式 (14) 更新位置。每次迭代后, 重新计算适应度并进行比较, 找出并更新至最优位置, 若满足终止条件, 则将其输出, 否则返回继续寻优, 直到得到 σ_{best}^2 和 C_{best} 的最优解。最后, 将寻优得到的 σ_{best}^2 和 C_{best} 代入到 LSSVM 模型中, 得到腐蚀速率预测模型的输出, 如图 2 所示。

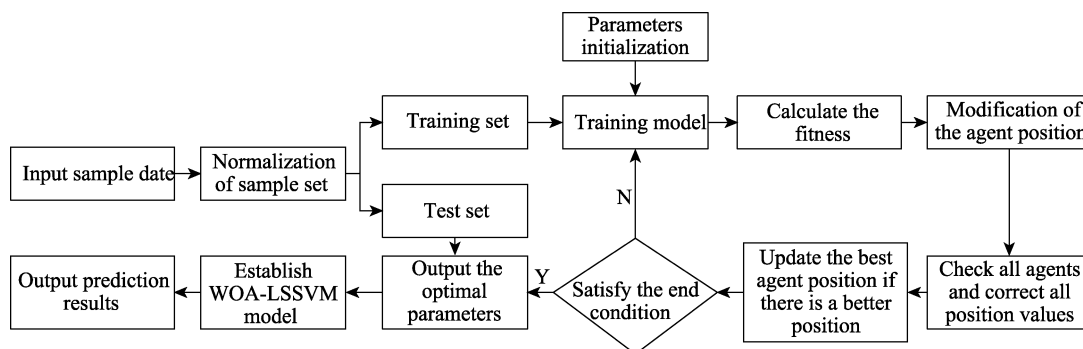


图 2 腐蚀预测流程

Fig.2 Flow chart of corrosion prediction

2.3 模型验证指标

为了验证 WOA-LSSVM 模型的预测效果, 本文选择以下三项指标对模型性能进行分析, 即均方根误差 (Root Mean Square Error, RMSE)、平均绝对百分误差 (Mean Absolute Percentage Error, MAPE) 和决定系数 (Coefficient of Determination, R^2)。计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

$$\text{MAPE} = 100 \times \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (19)$$

$$R^2 = \frac{\left(n \sum_{i=1}^n y_i \hat{y}_i - \sum_{i=1}^n y_i \sum_{i=1}^n \hat{y}_i \right)^2}{\left[n \sum_{i=1}^n \hat{y}_i^2 - \left(\sum_{i=1}^n \hat{y}_i \right)^2 \right] \left[n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2 \right]} \quad (20)$$

其中, n 是样本总量, y_i 为测试样本的预测值, \hat{y}_i 为真实值。决定系数 R^2 介于 0 到 1 之间, 且越接近 1, 模型拟合度越高, 性能越优良。

3 实例应用

3.1 数据准备

表 1 提供了在不同海水环境参数下 50 组海洋挂片腐蚀速率的数据^[25], 以电流密度 ($1 \mu\text{A}/\text{cm}^2$) 为单位来表征腐蚀速率, 钢材腐蚀情况见图 3。

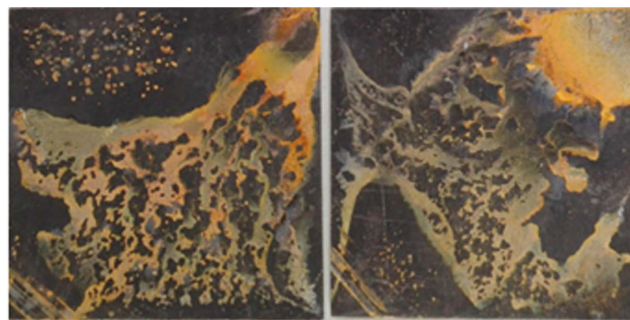


图 3 钢材腐蚀形貌图

Fig.3 Corrosion morphology of steel

表 1 海洋挂片腐蚀数据
Tab.1 Test data of marine corrosion

Serial number	Ocean temperature/℃	Dissolved oxygen/(mg·L ⁻¹)	Salinity /(×10 ³ mg·L ⁻¹)	pH	Redox potential/mV	Corrosion rate /(μA·cm ⁻²)
1	25.90	6.71	30.10	5.10	378	16.40
2	29.35	6.09	29	6.3	400	16.9
3	27.9	6.18	31.5	7	363	15.57
4	24	7.95	30.2	8.1	324	13.65
5	28	5.05	31.4	9.2	240	13.24
6	27.32	3.21	29.31	8.2	281	12.91
7	27.87	6.55	31.68	7.2	356	14.06
8	28.27	6.98	28.2	6.6	384	15.47
9	30.7	7.15	31.74	6.5	401	16.28
10	29.37	6.82	30.12	6.2	414	17.11
...
41	29.37	6.82	30.12	6.2	414	15.39
42	29.35	6.09	29	6.3	400	16.45
43	27	6.7	30.7	7	350	12.6
44	24.95	6.8	16.29	7.82	341	9.07
45	25.55	6.67	31	8.09	320	12.49
46	27.32	3.12	29.31	8.2	281	13.59
47	24.11	6.38	41	7.98	228	8.99
48	17.45	7.48	34.08	8.1	135	17.05
49	21.95	8.28	34.64	7.95	113	17.34
50	27.19	4.91	33.5	7.99	275	15.48

3.2 LASSO 变量选择

首先通过交叉验证法确定 LASSO 回归模型的惩罚力度，由图 4 可知，经交叉验证得到的正则化参数 λ 为 0.297 15。图 5 为在 λ 为不同取值下各变量惩罚函数值的变化情况及筛选结果。由图 5 可知，当 λ 为 0.297 15 时，有两个变量的惩罚函数值收敛为 0，故将这两个变量剔除，筛选后，得到海洋管线腐蚀速率的影响变量为温度、溶解氧含量和 pH 值。

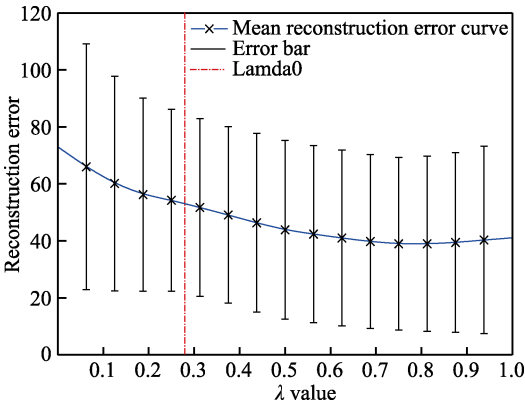


图 4 交叉验证过程
Fig.4 Cross validation process

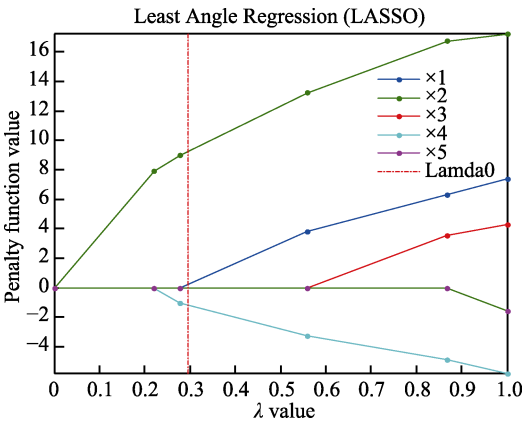


图 5 LASSO 拟合的系数轨迹
Fig.5 Coefficient trajectories fitted by LASSO

3.3 结果分析与模型对比

将经筛选后的数据分为两组，选取其中 42 组作为 WOA-LSSVM 的训练集，其余 8 组为检测集，模型在训练中的迭代进化过程如图 6 所示。经迭代寻优后的最优参数 $C_{\text{best}}=619.2068$ ， $\sigma_{\text{best}}^2=14.8045$ ，并将两参数代入到 LSSVM 中进行预测。

为检验 WOA-LSSVM 模型的预测精度，选用 FOA-LSSVM 和 LSSVM 两个模型与之进行对比，结

果如图7所示,相对误差对比结果见图8和表2。由图7可以看出,相较于LSSVM和FOA-LSSVM两个模型,WOA-LSSVM的预测值与真实值的差距较小,

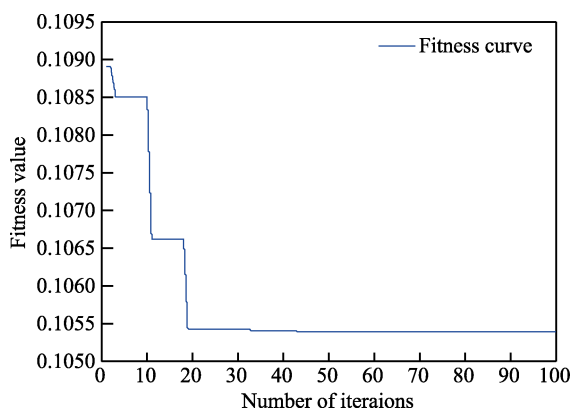


图6 WOA-LSSVM 迭代过程
Fig.6 Iteration process of WOA-LSSVM

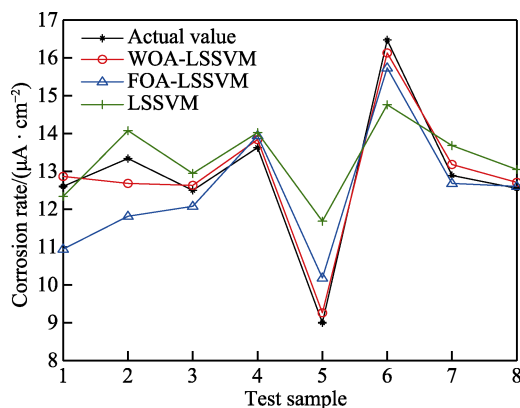


图7 预测结果对比图
Fig.7 Comparison of prediction results

拟合效果更佳。结合图8和表2的分析可知,除第7、8两组数据外,WOA-LSSVM的预测相对误差均小于其余两个模型。且就相对误差的平均值来看,LSSVM、FOA-LSSVM、WOA-LSSVM的平均相对误差分别为8.01%、6.28%、2.23%,WOA-LSSVM的平均相对误差值明显低于另外两者,亦可证明该模型的预测精度最高。

为进一步评价模型的预测性能,采用前文所述的三个统计学指标对模型进行评价,其分析结果见表3。从均方根误差(RMSE)这个指标来看,WOA-LSSVM分别比FOA-LSSVM和LSSVM减少了0.6107和0.8939;从平均绝对百分误差(MAPE)这个指标来看,WOA-LSSVM又分别比两者降低了4.06%和5.79%。而WOA-LSSVM的决定系数 R^2 达到了0.9708,远高于两个对照模型,说明模型的拟合度较高,预测效果更好。

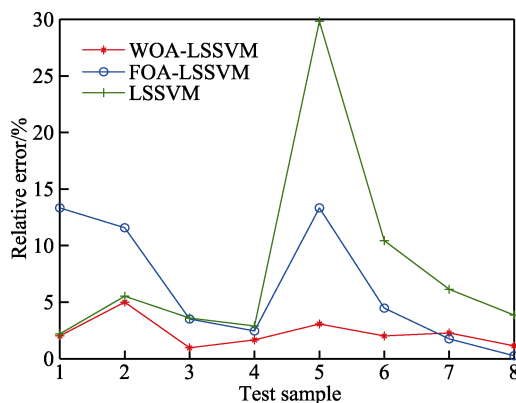


图8 相对误差对比图
Fig.8 Comparison of relative errors

表2 预测相对误差结果分析
Tab.2 Analysis of relative error results

Test samples	Actual corrosion rate $/(\mu A \cdot cm^{-2})$	WOA-LSSVM		FOA-LSSVM		LSSVM	
		Prediction value	RE/%	Prediction value	RE/%	Prediction value	RE/%
1	12.60	12.8495	1.98	10.9289	13.26	12.3313	2.13
2	13.33	12.6642	4.99	11.7910	11.55	14.0588	5.47
3	12.49	12.6064	0.93	12.0594	3.45	12.9376	3.58
4	13.61	13.8290	1.61	13.9379	2.41	14.0009	2.87
5	8.99	9.2594	3.00	10.1839	13.28	13.6677	29.78
6	16.45	16.1303	1.94	15.7222	4.42	14.7428	10.38
7	12.89	13.1769	2.23	12.6719	1.69	13.6716	6.06
8	12.55	12.6903	1.12	12.5808	0.25	13.0285	3.81

表3 模型预测性能指标对比
Tab.3 Comparison of model performance indicators

Model	RMSE	MAPE/%	R^2
LSSVM	1.2187	8.0119	0.5896
FOA-LSSVM	0.9655	6.2883	0.7424
WOA-LSSVM	0.3248	2.2250	0.9708

由于海洋环境复杂多变,影响管道腐蚀速率的因素较多,且某些指标难以测量和定量化,故在实际研究中无法将海洋挂片数据的所有影响指标纳入分析。未来可根据综合指标的管线腐蚀数据进行分析预测,进一步提高海洋管线外腐蚀速率预测的精确性和科学性。

4 结论

1) 采用 LASSO 回归算法, 确定海底管道腐蚀速率的主要影响指标, 降低了 LSSVM 输入变量的维度。作为传统支持向量机的改良, 使用最小二乘支持向量机避免了二次规划问题的求解, 提高了收敛速度, 节约了运算成本。

2) 使用 WOA 对 LSSVM 的惩罚因子 C 和核函数宽度 σ^2 两个参数进行优化, 将预测的平均相对误差降低至 2.23%, 提高了迭代速度和预测精度, 证明了模型具有较高的可靠性和良好的预测性能, 也为深海油气集输系统平台等结构的安全风险预警与防范提供了较为可靠的数据和理论支持。

参考文献:

- [1] WU Wei, PAN Yue, LIU Zhi-yong, et al. Electrochemical and stress corrosion mechanism of submarine pipeline in simulated seawater in presence of different alternating current densities[J]. Materials, 2018, 11(7): 1074.
- [2] WANG Chen, MA Gang, LI Jun-fei, et al. Prediction of corrosion rate of submarine oil and gas pipelines based on IA-SVM model[J]. IOP conference series: Earth and environmental science, 2019, 242: 022023.
- [3] LI Xin-hong, CHEN Guo-ming, ZHU Hong-wei, et al. Quantitative risk assessment of submarine pipeline instability[J]. Journal of loss prevention in the process industries, 2017, 45(1): 108-115.
- [4] 骆正山, 王瑞, 毕傲睿. Frechet 分布的海底油气管道腐蚀预测[J]. 腐蚀与防护, 2017, 38(3): 214-218.
LUO Zheng-shan, WANG Rui, BI Ao-rui. Corrosion forecast of offshore oil and gas pipelines based on Frechet distribution[J]. Corrosion and protection, 2017, 38(3): 214-218.
- [5] 骆正山, 袁宏伟. 基于误差补偿的 GM-RBF 海底管道腐蚀预测模型[J]. 中国安全科学学报, 2018, 28(3): 96-101.
LUO Zheng-shan, YUAN Hong-wei. GM-RBF model-based error compensation for prediction of submarine pipeline corrosion [J]. China safety science journal, 2018, 28(3): 96-101.
- [6] 王庆锋, 雷兴国. 基于无偏灰色马尔可夫链组合模型的管线腐蚀剩余寿命预测[J]. 腐蚀与防护, 2018, 39(2): 136-140.
WANG Qing-feng, LEI Xing-guo. Prediction of residual service life of pipelines based on unbiased grey and markov chain composite model[J]. Corrosion and protection, 2018, 39(2): 136-140.
- [7] 邓志安, 李姝仪, 李晓坤, 等. 基于模糊神经网络的海洋管线腐蚀速率预测新方法[J]. 中国腐蚀与防护学报, 2015, 35(6): 571-576.
DENG Zhi-an, LI Shu-yi, LI Xiao-kun, et al. A prediction method based on fuzzy neural network for corrosion rate of marine pipelines[J]. Journal of Chinese Society for Corrosion and Protection, 2015, 35(6): 571-576.
- [8] 李响, 余建星, 苗春生, 等. 基于遗传算法 SVM 的海洋环境腐蚀速率预测[J]. 中国海洋平台, 2018, 33(5): 56-62.
LI Xiang, YU Jian-xing, MIAO Chun-sheng, et al. Prediction of corrosion rate in marine environment based on support vector machine combining with genetic algorithm[J]. China offshore platform, 2018, 33(5): 56-62.
- [9] 田宇, 兰旭. 温度及流速对 X70 海底管线腐蚀速率的影响[J]. 全面腐蚀控制, 2018, 32(3): 62-68.
TIAN Yu, LAN Xu. Influences of temperature and velocity on corrosion rate of X70 subsea pipelines[J]. Total corrosion control, 2018, 32(3): 62-68.
- [10] 李延伟, 李言涛, 王路遥, 等. 海底海泥区域管线钢腐蚀行为的研究现状及展望[J]. 材料保护, 2012, 45(3): 56-58.
LI Yan-wei, LI Yan-tao, WANG Lu-yao, et al. Current status and prospect of study on corrosion behavior of submarine pipelines in sea mud[J]. Materials protection, 2012, 45(3): 56-58.
- [11] 马钢, 李俊飞, 戴政, 等. 海底油气管道腐蚀及防护研究[J]. 石油化工腐蚀与防护, 2019, 36(1): 1-5.
MA Gang, LI Jun-fei, DAI Zheng, et al. Study on corrosion and protection of submarine pipeline[J]. Corrosion & protection in petrochemical industry, 2019, 36(1): 1-5.
- [12] 罗文强. 海洋工程平台油气集输压力容器灰色系统研究[D]. 兰州: 兰州理工大学, 2016.
LUO Wen-qiang. Research of grey system on oil-gas gathering and transferring pressure vessel in marine engineering platform[D]. Lanzhou: Lanzhou University of Technology, 2016.
- [13] 徐应波, 何素娟, 闫化云, 等. 动态环道腐蚀评价系统在某油田海底管道流速研究中的应用[J]. 全面腐蚀控制, 2013, 27(11): 66-69.
XU Ying-bo, HE Su-juan, YAN Hua-yun, et al. Application of flow loop on flow rate study in oilfield pipeline [J]. Total corrosion control, 2013, 27(11): 66-69.
- [14] 王大荣, 张忠占. 线性回归模型中变量选择方法综述[J]. 数理统计与管理, 2010, 29(4): 615-627.
WANG Da-rong, ZHANG Zhong-zhan. Variable selection for linear regression models: A survey[J]. Journal of applied statistics and management, 2010, 29(4): 615-627.
- [15] 刘小瑜, 辛韵. 基于 LASSO-VIP-PLSR 模型的出口商品价格总指数的预测[J]. 统计与决策, 2019, 35(15): 79-82.
LIU Xiao-yu, XIN Yun. Prediction of total export commodity price index based on LASSO-VIP-PLSR model [J]. Statistics & decision, 2019, 35(15): 79-82.
- [16] MAEDE H A, KARIM K, ABDOLAZIM S P. Developing of predictive models for pneumonitis with forward variable selection and LASSO logistic model for breast cancer patients treated with 3D-CRT[J]. Polish journal of

- medical physics and engineering, 2018, 24(2): 149-156.
- [17] LI Qing-qing. Logistic and SVM credit score models based on lasso variable selection[J]. Journal of applied mathematics and physics, 2019, 7(5): 1131-1148.
- [18] 郑立. 基于 RS-LSSVM 制造业上市公司财务危机预警模型[J]. 工业技术经济, 2019, 38(7): 108-113.
ZHENG Li. Financial crisis warning model of manufacturing listed companies based on RS-LSSVM[J]. Journal of industrial technological economics, 2019, 38(7): 108-113.
- [19] LIANG Jin-jin. Steepest descent method based LSSVM model[J]. Journal of physics: conference series, 2019, 1237: 052014.
- [20] ZHU Xing, MA Shu-qi, XU Qiang, et al. A WD-GA-LSSVM model for rainfall-triggered landslide displacement prediction[J]. Journal of mountain science, 2018, 15(1): 156-166.
- [21] 刁俊科, 崔东文. 基于鲸鱼优化算法与投影寻踪耦合的云南省初始水权分配[J]. 自然资源学报, 2017, 32(11): 1954-1967.
DIAO Jun-ke, CUI Dong-wen. Initial water rights allocation in Yunnan based on whale optimization algorithm-projection pursuit model[J]. Journal of natural resources, 2017, 32(11): 1954-1967.
- [22] 滕德云, 滕欢, 潘晨, 等. 基于鲸鱼优化算法的无功优化调度[J]. 电测与仪表, 2018, 55(24): 51-58.
TENG De-yun, TENG Huan, PAN Chen, et al. Reactive power optimal dispatch based on whale optimization algorithm[J]. Electrical measurement & instrumentation, 2018, 55(24): 51-58.
- [23] ANKIT K S, AKASH S. A demand side management control strategy using whale optimization algorithm[J]. SN applied sciences, 2019, 1(8): 1-15.
- [24] SEYEDALI M, ANDREW L. The whale optimization algorithm[J]. Advances in engineering software, 2016, 95: 51-67.
- [25] 骆正山, 李易安, 骆济豪, 等. 基于 AGA-ELM 混合算法的海底管线腐蚀速率预测[J]. 材料保护, 2019, 52(8): 51-56.
LUO Zheng-shan, LI Yi-an, LUO Ji-hao, et al. Corrosion rate prediction of subsea pipelines based on AGA-ELM hybrid algorithm[J]. Materials protection, 2019, 52(8): 51-56.

(上接第 223 页)

- [12] CUI Yu-hong, LI Hai-tao, XIANG Heng-gao, et al. Plastic deformation in zinc-blende AlN under nanoindentation: A molecular dynamics simulation[J]. Applied surface science, 2019, 466(1): 757-764.
- [13] XIANG Heng-gao, LI Hai-tao, FU Tao. Formation of prismatic loops in AlN and GaN under nanoindentation[J]. Acta materialia, 2017, 138(1): 131-139.
- [14] STUKOWSKI A. Visualization and analysis of atomistic simulation data with OVITO—the open visualization tool[J]. Mater sci eng, 2009, 18(8): 015012.
- [15] VERLET L. Computer “experiment” on classical fluids. I. Thermodynamical properties of Lennard-Jones molecules[J]. Health physics, 1967, 22(1): 79-85.
- [16] FOILES S M, BASKES M I, DAW M S. Embedded-atom-method functions for the fcc metals Cu, Ag, Au, Ni, Pd, Pt, and their alloys[J]. Physical review B, 1988, 33(12): 7983-7991.
- [17] MORSE P M. Diatomic molecules according to the ware mechanics II: Vibrational levels[J]. Physical review, 1929, 34(4): 57-64.
- [18] QIAN Y, SHANG F, WAN Q. A molecular dynamics study on indentation response of single crystalline wurtzite GaN[J]. Journal of apply physical, 2018, 24(11): 115102.
- [19] QIAN Y, SHANG F, WAN Q. The mechanism of plastic deformation in intact and irradiated GaN during indentation: A molecular dynamics study[J]. Computer material science, 2018, 149(15): 230-242.
- [20] GOEL S, LUO X, REUBEN R L. Shear instability of nanocrystalline silicon carbide during nanometric cutting[J]. Applied physical letter, 2012, 100(23): 231-238.
- [21] GOEL S, BEAKE B, CHAN C, et al. Twinning anisotropy of tantalum during nanoindentation[J]. Material science engineering A, 2015, 627(11): 249-261.
- [22] XIANG Heng-gao, LI Hai-tao, PENG Xiang-he. Comparison of different interatomic potentials for MD simulations of AlN[J]. Computational materials science, 2017, 140(23): 113-120.
- [23] CHEN J J, ZHANG H, XIANG H G. Atomistic modelling of interface structure and deformation mechanisms in the Al/GaN multilayer under compression[J]. Molecular simulation, 2019, 45(11): 921-926.
- [24] CHEN Chen, LI Hai-tao, XIANG Heng-gao, et al. Molecular dynamics simulation on B₃-GaN thin films under nanoindentation[J]. Nanomaterials, 2018, 8(10): 856-862.
- [25] LI Hai-tao, XIANG Heng-gao, HUANG Hong-zhi, et al. Interface structure and deformation mechanisms of AlN/GaN multilayers[J]. Ceramics international, 2020, 46(8): 11556-11562.