

基于主成分和粒子群优化支持向量机的 管道内腐蚀预测

毕傲睿¹, 骆正山¹, 乔伟², 孙阳阳³

(1.西安建筑科技大学 管理学院, 西安 710055; 2.中煤科工集团西安研究院有限公司, 西安 710054; 3.中国华能集团清洁能源技术研究院有限公司, 北京 102209)

摘要: **目的** 研究输油金属管道内腐蚀预测模型, 以改善管道维修策略和提高使用期限。**方法** 分析输油管道内腐蚀原因, 归纳腐蚀因素, 采用主成分分析法对腐蚀因素进行优选, 摒弃相关联但腐蚀贡献率较低的因素, 以最大化表征腐蚀原因及减少不必要的处理过程。将贡献率较大的腐蚀因素作为支持向量机预测模型的输入变量, 以腐蚀率作为目标输出, 建立管道腐蚀预测模型。针对支持向量机参数选取问题, 应用鲈鱼粒子群算法进行寻优, 以提高预测精度。以 20#钢管为例进行了模型验证, 并与其他预测模型进行了对比和分析。**结果** 主成分分析筛选得到的管道内腐蚀的主要因素有: H_2S 、 CO_2 、 Cl^- 、酸碱值、压力、介质温度、流速。通过鲈鱼粒子群算法改进的支持向量机模型的预测与实际值的平均相对误差为 2.82%, 相关性系数值为 0.9955, 均优于其他三种预测模型。**结论** 金属管道的内腐蚀由多个腐蚀因素共同作用形成, 采用主成分和粒子群优化的支持向量机模型能够精确预测内腐蚀率, 对金属管道维修和管理的借鉴性高。

关键词: 内腐蚀; 腐蚀因素; 腐蚀率预测; 主成分分析; 支持向量机; 鲈鱼粒子群

中图分类号: TG172 **文献标识码:** A **文章编号:** 1001-3660(2018)09-0133-08

DOI: 10.16490/j.cnki.issn.1001-3660.2018.09.018

Prediction of Pipeline Inner-corrosion Based on Principal Component Analysis and Particle Swarm Optimization-support Vector Machine

BI Ao-rui¹, LUO Zheng-shan¹, QIAO Wei², SUN Yang-yang³

(1.School of Management, Xi'an University of Architecture & Technology, Xi'an 710055, China;
2. Xi'an Research Institute, China Coal Technology and Engineering Group Corp, Xi'an 710054, China;
3.China Huaneng Clean Energy Research Institute, Beijing 102209, China)

ABSTRACT: The work aims to improve the maintenance strategy and service life by studying the prediction model for inner-corrosion of metal pipelines. The causes and factors for inner-corrosion of pipeline were analyzed and summed up. The cor-

收稿日期: 2018-05-03; 修订日期: 2018-07-10

Received: 2018-05-03; **Revised:** 2018-07-10

基金项目: “十三五”国家重点研发计划项目 (2017YFC0804100); 国家自然科学基金项目 (61271278); 陕西省教育厅自然科学基金项目 (16JK1465); 中国华能集团清洁能源技术研究院基金项目 (TX-15-CERI02)

Fund: Supported by Project of National Key Research and Development Program of China in the 13th Five-year Plan (2017YFC0804100), National Natural Science Foundation of China (61271278), Project of Education Department of Shaanxi Provincial Government (16JK1465) and Foundation of China Huaneng Group Clean Energy Research Institute (TX-15-CERI02)

作者简介: 毕傲睿 (1987—), 男, 博士研究生, 主要研究方向为油气管道风险管理。

Biography: BI Ao-rui (1987—), Male, Doctoral candidate, Research focus: risk management of oil and gas pipelines.

通讯作者: 骆正山 (1969—), 男, 博士, 教授, 主要研究方向为油气田材料防腐与检测、管道风险管理。

Corresponding author: LUO Zheng-shan (1969—), Male, Doctor, Professor, Research focus: corrosion prevention and inspection of oil and gas field materials, risk management of pipelines.

rosion factors were filtered by the principal component analysis. Those factors related to each other but contributing to low corrosion were abandoned. The causes for corrosion were characterized at maximum and some unnecessary analysis processes were reduced. The factors contributing to large corrosion were used as the input variables to the support vector machine prediction model, and the corrosion rate was used as the target output to build the pipeline corrosion prediction model. Aiming at parameter selection of support vector machines, catfish particle swarm optimization algorithm was applied to improve the prediction accuracy. 20# pipeline was taken as an example to verify the model. The model was contrasted and compared with other prediction models. The main factors for inner-corrosion of pipeline selected by the main component analysis were H_2S , CO_2 , Cl^- , pH, pressure, medium temperature and current velocity. The average relative error between the predicted value of support vector machine model improved by catfish particle swarm optimization algorithm and the actual value was 2.82% and the correlation coefficient value was 0.9955, which were better than those in the other three prediction models. The inner-corrosion of pipeline is formed by multiple corrosion factors, and the inner-corrosion rate can be predicted accurately by the support vector machine model adopting main component analysis and particle swarm optimization, which provide a reference for the maintenance and management of the metal pipelines.

KEY WORDS: inner-corrosion; corrosion factors; corrosion rate prediction; principal component analysis; support vector machine; catfish particle swarm

由于介质成分复杂, 加上温度、地形等的作用, 金属输油管道内易产生腐蚀性物质, 进而形成内腐蚀。内腐蚀造成管道内壁减薄, 导致结构强度降低、破坏泄漏等, 并且由此引起的事故具有隐蔽性, 后果往往也比较严重^[1-2]。目前, 内腐蚀的危害已超过了外腐蚀, 是管道失效的主要原因, 因此研究输油管道的内腐蚀问题对管道工程设计和防腐管理具有重要的现实意义。

国内外对管道内腐蚀现象已展开了一定的研究。张伟刚等^[3]通过扫描电镜研究了原油环境中不同温度和硫含量下 X80 管道的腐蚀行为。张弦等^[4]通过对腐蚀形貌、腐蚀产物分析, 研究了低碳钢在 H_2S 溶液中的腐蚀规律。方晓君等^[5]研究了流速对管道腐蚀率的影响, 得出动态比静态原油更具腐蚀性的结论。Jenny Been^[6]应用电化学技术测量了大口径输油管道沉积物信息, 发现沉积物过多, 极易造成管道的微生物腐蚀等。但是, 内腐蚀是一个非线性的过程^[7], 现有研究多从单一角度对腐蚀状况进行整体分析, 往往忽略了腐蚀因素间的促进或抑制关系的影响。而在多种腐蚀因素共存的条件下, 很难采用数学方法建立有效的内腐蚀率描述模型, 导致预测结果存在误差。

为了综合考虑各腐蚀因素及因素间的互相关性对内腐蚀的影响, 本文通过归纳腐蚀因素, 在考虑互相关性的基础上, 应用主成分分析法得到腐蚀主因素, 构建支持向量机预测模型, 同时针对模型参数, 应用粒子群算法进行优化, 最终实现管道内腐蚀率的精确预测。并将模型进行实证, 以检验其有效性和适用性。

1 管道内腐蚀影响因素分析

金属管道的内腐蚀实际上是腐蚀和冲刷交互影

响的过程, 一般将其分为均匀腐蚀、坑蚀、应力腐蚀、冲刷腐蚀及微生物腐蚀 5 类, 分别解释如下:

1) 均匀腐蚀, 指管道内表面金属因腐蚀介质而产生的全面性腐蚀。通常 H_2S 、 CO_2 等气体溶于管壁上的液体, 生成酸性物质, 造成均匀腐蚀, 进而导致管壁均匀减薄、断裂等。

2) 坑蚀, 指由于管道材料、内壁的不均匀以及管道保护膜结晶剥裂, 造成部分区域的优先腐蚀。管道输送的气体 and 液体均会导致坑蚀, 坑蚀会造成管道穿孔, 并诱发疲劳损伤等破坏。

3) 应力腐蚀, 指管道金属部分在应力和某些介质综合作用下产生的应力脆断现象。因为 H_2S 在水中分解生成 HS^- , 加速阴极析氢, 产生氢压, 最终在管道内部形成拉应力^[8], 改变管道受力模式, 造成破坏。

4) 冲刷腐蚀。管道金属表面的腐蚀物在气速较高时会被冲走, 造成新金属面的暴露和再腐蚀, 加速腐蚀进程^[9]。

5) 微生物腐蚀, 指传输介质中含有细菌微生物而加剧管道腐蚀的现象。遭受微生物腐蚀影响的管道具有很大的不确定性, 这种不确定性对管道的腐蚀来说影响非常复杂^[10]。

根据上述腐蚀机理, 结合已有研究, 本文归纳出管道内腐蚀的影响因素共计 34 种, 分为油气特性、管道性质、运行参数、微生物菌类及其他, 如表 1 所示。

表 1 中 34 种因素对内腐蚀的形成均有作用, 但程度各不相同。部分因素之间直接或间接地还互有影响(促进或抑制), 例如压力越大, 越容易出现液态水; H_2S 在高压下溶解度变大, 同时高压下气速和流速增大, 最终导致腐蚀加剧。因此为合理预测内腐蚀, 需要对上述腐蚀因素进行筛选, 在考虑因素间互关联性的前提下, 同时减少不必要的分析。

表 1 内腐蚀影响因素
Tab.1 Factors for pipeline inner-corrosion

Categories	Inner-corrosion factors
Properties of oil and gas	H ₂ S, CO ₂ , Cl ⁻ , Sulfide, pH, Shear force between liquid and pipe wall, Shear force between gas and pipe wall, Surface tension, Viscosity, Density of liquid, Density of gas, Flow state, Oxygen content, Wax content
Operating parameters	Pressure, Temperature, Velocity of flow, Velocity of gas, Gas-liquid ratio, Oil-water ratio, Liquid holdup, Water content
Pipeline properties	Dip angle, Difference in elevation, Diameter of inner-wall, Surface temperature of inner-wall
Bacteria	Sulfate reducing bacteria (SRB), Saprophytic bacteria, Iron bacteria
Other	Adhesion of corrode, Suspended solids, Deposition rate, Salinity, Corrosion inhibitor mass concentration

2 主成分分析法

针对内腐蚀因素, 本文应用主成分分析法 (Principal component analysis, PCA) 进行筛选。PCA 是一种多元统计方法^[11], 是通过线性变换从因素集中筛选出代表整个因素集性质的少数因素, 以达到不失真的情况下简化分析的目的, 特别适合管道内腐蚀这种因素互相关联度比较高的情况^[12-13]。其数学描述如下:

设有 n 个样本 x_1, x_2, \dots, x_n , 每个样本有 m 个属性, 现将 m 个属性映射减少到 k 个 ($k < m$)。

1) 初始矩阵标准化:

$$a_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j} \quad (1)$$

式中: $i=1, 2, \dots, n; j=1, 2, \dots, m; \bar{x}_j = \frac{\sum_{i=1}^n x_{ij}}{n}$,

s_j 为标准差, $s_j = \sqrt{\frac{\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2}{n-1}}$ 。令标准化矩阵

$$A = \begin{bmatrix} A_1^T \\ A_2^T \\ \vdots \\ A_n^T \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n1} & \cdots & a_{nm} \end{bmatrix}。$$

2) 标准化矩阵的相关阵 R :

$$R = [r_{ij}]_{m \times m} = \frac{A^T A}{n-1} \quad (2)$$

式中: $i, j=1, 2, \dots, m; r_{ij} = \sum_{k=1}^n A_{kj} \cdot A_{ki} / (n-1)$ 。

3) 特征值 λ_j :

$$|R - \lambda_j E| = 0 \quad (3)$$

式中: $j=1, 2, \dots, m; E$ 为单位矩阵。

4) 累积贡献率 M :

$$M = \sum_{j=1}^k \lambda_j / \sum_{i=1}^m \lambda_i \quad (4)$$

累积贡献率 M 表示主成分累积提取了原始变量多少的度量。

5) 特征向量 b_j^0 :

解方程组 $Rb = \lambda_j b$ 得到特征值的特征向量并将

其归一化。

$$b_j^0 = \frac{b_j}{\|b_j\|} \quad (5)$$

式中: b_j 为特征向量, b_j^0 为单位特征向量。

3 支持向量机预测模型

支持向量机 (Support vector machine, SVM) 是一种机器学习分析模型, 目前已逐渐应用于预测、识别等领域^[14-16]。SVM 是建立在结构风险最小化 (Structural risk minimization, SRM) 原理上的^[17], 可根据有限的样本, 达到最好的学习能力, 能有效地进行回归预测。SVM 回归预测模型的数学描述如下:

$$f(x) = \sum_{x_i \in SVs} (\alpha_i - \alpha_i^*) K(x \cdot x_i) + b \quad (6)$$

式中: α_i, α_i^* 为拉格朗日乘子; b 为偏置; SVs 为支持向量集; $K(x \cdot x_i)$ 为核函数, 作用是使函数直接在低维输入空间上求解, 以减少高维空间的复杂运算。本文选用性能稳定的高斯径向基核函数 (Gaussian radial basis function, RBF)^[18]:

$$K(x \cdot x_i) = \exp \left(-\frac{\|x - x_i\|^2}{2\sigma^2} \right) \quad (7)$$

式中: σ 为核参数, 反映训练样本数据的分布特性。拉格朗日乘子和偏置由下式获得:

$$\min_{\alpha_i, \alpha_i^*} \frac{1}{2} \sum_{i=1}^{n-m} \sum_{j=1}^{n-m} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) - \sum_{i=1}^{n-m} (x_{i+m} \alpha_i^* - \alpha_i) + \varepsilon \sum_{i=1}^{n-m} (\alpha_i + \alpha_i^*) \quad (8)$$

约束条件为: $\sum_{i=1}^{n-m} (\alpha_i - \alpha_i^*) = 0, 0 \leq \alpha_i^* \leq C, i=1,$

$2, \dots, n-m$ 。其中 C 为惩罚参数。

从式 (6) 至 (8) 可以看出, 参数 C 、 σ 和 ε 影响着模型的预测精度和泛化能力。惩罚因子 C 值越高, 说明越不能容忍误差, 但是容易过拟合; 值越小, 则容易欠拟合; 过大或过小都会导致模型泛化能力变差。 σ 反映训练样本数据的分布特性。不敏感损失参数 ε 是一个大于零的值, 是忽略真实值在某个范围内

的误差,决定着支持向量的个数。目前通过先验知识、网格交叉验证等方式获得这3个参数的具体值,但这些方法主观,易陷入局部最优,并且在样本较大时,运算量大、耗时长,严重影响支持向量机的实际使用,因此需要对参数进行优化选择。

4 粒子群优化算法

为提高内腐蚀预测精度,本文应用粒子群(Particle swarm optimization, PSO)算法处理SVM的参数优化问题。假设参数的潜在最优解是其值域空间的一个粒子,而粒子具有速度和位置属性,并且其优秀程度由适应值(Fitness value)决定^[19],因此速度与位置可用如下公式更新:

$$v_{i,n}^{j+1} = w \cdot v_{i,n}^j + c_1 \cdot \text{rand}() \cdot (\text{pbest}_{i,n}^j - x_{i,n}^j) + c_2 \cdot \text{rand}() \cdot (\text{gbest}_n^j - x_{i,n}^j) \quad (9)$$

$$x_{i,n}^{j+1} = x_{i,n}^j + v_{i,n}^{j+1} \quad (10)$$

式中: $v_{i,n}^j$ 和 $x_{i,n}^j$ 分别为粒子 i 在第 j 次迭代中第 n 维的速度和位置; $\text{pbest}_{i,n}^j$ 是粒子 i 在第 n 维的个体极值的位置; gbest_n^j 是群体在第 n 维的全局极值的位置; c_1 和 c_2 为学习因子; $\text{rand}()$ 为 $(0,1)$ 之间的随机数; w 为惯性权重。实际应用时发现,该算法有早收敛现象,此时需要跳出局部最优解,以找到全局最优

解^[20],因此本文通过“鲶鱼效应”(catfish effect)^[21],优化式(9)。当粒子在局部最优解时,找一个粒子去改变粒子群在局部最优位置的停滞状态。优化后的算法称作鲶鱼粒子群(Cat-fish particle swarm optimization, CFPSO)算法,其粒子速度更新如下:

$$v_{i,n}^{j+1} = w \cdot v_{i,n}^j + c_1 \cdot \text{rand}() \cdot (f_1 \cdot \text{rand}() \cdot \text{pbest}_{i,n}^j - x_{i,n}^j) + c_2 \cdot \text{rand}() \cdot (f_2 \cdot \text{rand}() \cdot \text{gbest}_n^j - x_{i,n}^j) \quad (11)$$

式中: $f_1 \cdot \text{rand}()$ 和 $f_2 \cdot \text{rand}()$ 称为鲶鱼算子,其定义如下:

$$f_1 \cdot \text{rand}() = \begin{cases} 1, & e_p > e_{bp} \\ f_1 \cdot \text{rand}(), & e_p \leq e_{bp} \end{cases} \quad (12)$$

$$f_2 \cdot \text{rand}() = \begin{cases} 1, & e_g > e_{bg} \\ f_2 \cdot \text{rand}(), & e_g \leq e_{bg} \end{cases}$$

式中: e_p 和 e_g 分别为当前值与当前个体最优值、当前全局最优值的偏差; e_{bp} 和 e_{bg} 分别为当前值与当前局部最优值、当前全局最优值的偏差的阈值。由定义可知,若当前值的偏差小于偏差阈值时,鲶鱼算子去改变个体最优值和全局最优值来跳出局部最优。

综上,对金属管道内腐蚀因素进行分析和归纳,应用PCA筛选具有代表性的主因素,并将这些因素作为CFPSO算法优化SVM预测模型的输入变量,以内腐蚀率作为输出变量进行训练,最终建立腐蚀预测模型,流程图如图1所示。

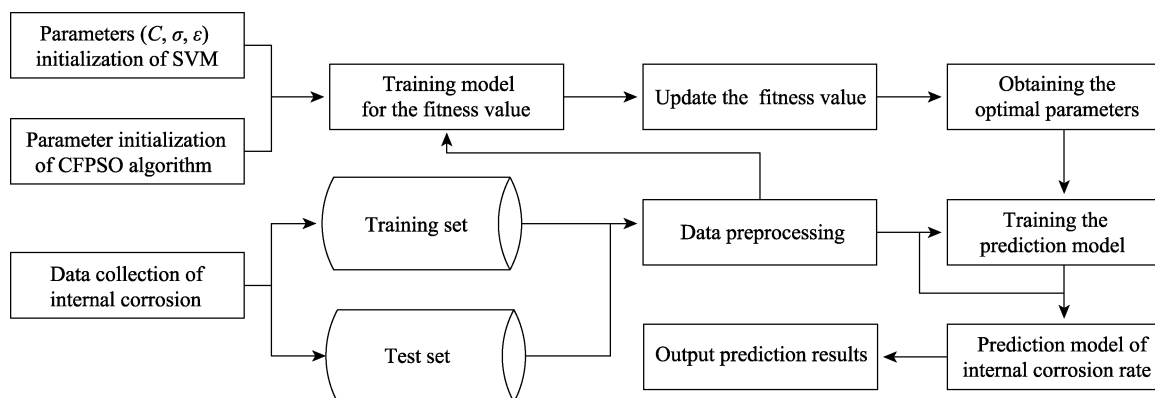


图1 管道内腐蚀预测流程
Fig.1 Prediction flow chart for pipeline inner-corrosion

5 实例应用

腐蚀数据采集于辽河油田曙光采油厂曙四联合站集输管道,管道规格 273 mm×7 mm,钢材型号 20#,采集方式为电阻法,设备为型号 IER2000 电阻测腐仪,探针采集数据见图2,其中40组数据作为SVM的训练集,10组数据作为检测集。

5.1 管道内腐蚀因素选取

对于表1内腐蚀因素进行预处理。其中,液体-

管壁剪切应力、气体-管壁剪切应力其实是流速和风速的作用结果。产物膜粘附力间接表征了腐蚀产物对管道的保护效果,通常会受到剪切力和拉力的破坏,因此从逆向考虑也是受流速和风速的间接影响。流态的不同是受油气密度、流速、风速、压力的综合作用。内壁表面温度受介质温度的影响(管道保温效果假设处于最佳状态)。沉积速率主要指原油中的蜡沉淀速率,为了反映管道中沉积蜡的多少,已有研究表明,表面沉积速率主要取决于分子扩散和热扩散^[22],因此沉积速率主要受原油蜡含量、温度以及流速的影响。




图 2 腐蚀率数据
Fig.2 Rates of corrosion

矿化度主要反映介质水中的含盐量，含盐量主要包括碳酸盐、氯化物以及硫酸盐等，而这些盐主要是由 H₂S 等酸性气体遇液体形成。硫酸盐还原菌对腐蚀的影响主要体现在产生的硫化物（FeS 等）上。腐生菌会增加液体黏度，并产生氧浓差。铁细菌在酸性环境下促使铁质形成 Fe(OH)₃ 胶状沉淀，改变 pH 值以及

液体黏性等。上述因素与部分腐蚀因素的影响重复，故不再考虑其作用。此外，内壁直径为常量，虽然内壁直径大的管道在弯头、三通等处冲刷腐蚀较多，但其在样本中没有区分度，不具备统计意义，并且内壁直径对腐蚀影响甚微，故该因素也不做考虑。因此预处理后的腐蚀因素共计 23 种。

对采集样本进行理化分析，并应用 SPSS19.0 软件对样本的 23 种腐蚀因素进行主成分分析，结果见表 2。其中，特征值表征主成分影响力的大小，即贡献了多少原始腐蚀因素信息，如果特征值小于 1，则表示该主成分的影响力不如原始腐蚀因素的平均影响力大。由表 2 可知，提取前 4 个主成分最合适，其累积贡献率为 82.91%，综合了内腐蚀的大部分信息。

表 3 为 4 个主成分的特征向量，特征向量的绝对值越大，则该因素对腐蚀的作用效果越具代表性。从表 3 可知，H₂S 和 CO₂ 在第一主成分上有较高值，Cl⁻ 和酸碱值在第二主成分上有较高值，流速和压力在第三主成分上有较高值，介质温度在第四主成分上有较高值。因此，将 H₂S、CO₂、Cl⁻ 含量、酸碱值、压力、

表 2 特征值和累积贡献率
Tab.2 Eigen value and cumulative variance contribution

Component number	Eigen value	Cumulative variance contribution/%	Component number	Eigen value	Cumulative variance contribution/%	Component number	Eigen value	Cumulative variance contribution/%
1	9.7743	32.73	9	0.5194	92.43	17	0.0799	99.54
2	7.5370	57.98	10	0.4987	94.09	18	0.0405	99.67
3	4.3233	72.49	11	0.4153	95.48	19	0.0362	99.80
4	3.1216	82.91	12	0.3738	96.72	20	0.0285	99.89
5	0.7144	85.30	13	0.2990	97.72	21	0.0267	99.98
6	0.5192	87.03	14	0.2585	98.58	22	0.0035	99.99
7	0.5120	88.74	15	0.1122	98.96	23	0.0027	100.00
8	0.5866	90.69	16	0.0946	99.27			

表 3 主成分的特征向量
Tab.3 Eigenvectors of principal components

Corrosion factors	PC ₁	PC ₂	PC ₃	PC ₄	Corrosion factors	PC ₁	PC ₂	PC ₃	PC ₄
H ₂ S	0.8198	0.3992	0.0041	0.0194	Difference in elevation	-0.4335	0.4652	0.2923	0.2897
CO ₂	0.9459	0.0692	-0.1359	-0.1572	Pressure	0.0648	0.5607	0.8082	-0.5167
Cl ⁻	0.6154	0.9637	0.3477	0.3885	Temperature	0.5625	0.0681	-0.2597	-0.8553
Sulfide	-0.1851	0.0746	-0.2409	-0.1675	Velocity of flow	0.6359	0.1834	0.9309	0.4558
pH	0.4225	0.8351	0.3777	0.3258	Velocity of gas	0.3001	0.4583	0.4235	0.4072
Surface tension	0.1358	0.1488	0.1540	0.2881	Gas-liquid ratio	0.4952	0.4080	0.4150	0.4693
Viscosity	-0.4401	0.5862	-0.6229	-0.0175	Oil-water ratio	-0.3212	-0.2709	-0.2551	-0.1462
Density of liquid	0.2065	-0.1551	0.5577	-0.5380	Liquid holdup	0.5503	0.5522	0.3447	0.4662
Density of gas	0.0472	-0.1463	-0.0612	0.5058	Water content	0.4367	0.5188	0.5864	-0.4020
Oxygen content	0.5087	-0.4285	-0.1728	0.5795	Suspended solids	0.5164	-0.4408	-0.5022	0.3757
Wax content	0.0269	0.0104	0.2397	0.1148	Corrosion inhibitor mass concentration	0.2388	0.4808	0.4397	0.2652
Dip angle	0.4790	0.4955	0.3311	0.5097					

介质温度、流速这 7 个因素作为管道内腐蚀因素的代表因素。其中 H_2S 在温度、压力等因素的多重影响下表现为很强的腐蚀性, 通常形成管壁点蚀, 其腐蚀物 (FeS) 会与内壁暴露的金属基体形成电位差, 加速裸露金属处的腐蚀; 同时 H_2S 析出的氢原子极易进入金属, 造成氢应力开裂 (SSC) 和氢致开裂 (HIC)。 CO_2 溶于游离水, 产生碳酸, 对管道产生点蚀、均匀腐蚀等; 同时其腐蚀物 ($FeCO_3$ 、 $CaCO_3$) 在管道内壁厚度不一, 极易形成腐蚀电偶, 造成局部腐蚀。由于其半径小、易穿透保护膜和腐蚀物, Cl^- 与金属基体形成 $FeCl_2$, $FeCl_2$ 水解后造成氢原子浓度剧增, 从而诱发点蚀和应力腐蚀。pH 值降低, 将会溶解内壁表面的氧化膜, 造成金属基体与酸性介质的直接接触。输送压力使内壁在与腐蚀面垂直的方向上受应力, 该应力和化学腐蚀协同作用, 加速腐蚀率。温度的升高会急剧加速腐蚀过程的化学反应。流速增大, 加快 Fe^{2+} 和电荷的转移速度, 进而加快了腐蚀; 但是当流速到达一定值后, 会加快腐蚀产物的生成, 形成更有保护性的产物膜。

5.2 支持向量机参数优化

对 SVM 进行优化, 以均方差作为 CFPSO 算法的粒子适应度值。算法的参数设置为: 参数搜索区间 $C \in [0.01, 100]$ 、 $\varepsilon \in [0.001, 1]$ 、 $\sigma \in [0.001, 1]$, 粒子群规模 $N=20$, 最大迭代次数 $K=500$, 惯性权重系数 $w = 0.9 - 0.5k/K$, k 为当前迭代次数, $c_1=c_2=2$, $f_1=1$, $f_2=4$, 偏差阈值 $e_{bg}=0$, $e_{bp}=0.01$ 。寻优过程的适应度变化曲线如图 3 所示, 由图可以看出, 适应度值随迭代次数的增加而趋于稳定; 当寻优为局部极值时, 会在其附近向下小范围地波动变化, 然后跳出该局部极值, 继

续进行搜索。通过 10^4 次寻优, 最终获得的 C 、 ε 、 σ 的最优值分别为 5.2433、0.0126 和 0.2250。




图 3 CFPSO 适应度变化曲线

Fig.3 Fitness changing curve of CFPSO

5.3 模型预测与结果分析

应用 MATLAB Libsvm2.98 工具箱进行编程, 将主成分分析得到的 7 个因素作为 SVM 的输入参数, 结合参数最优值, 用训练集训练并建立内腐蚀率预测模型, 最后用检测集来验证模型的预测效果。对模型评价标准采用相对误差, 同时为验证 CFPSO-SVM 的有效性, 选用三个对比模型: BP 神经网络 (Back propagation neural network, BPNN)、网格搜索优化的 SVM 和遗传算法 (Genetic algorithm, GA) 优化的 SVM, 其中, BP 神经网络采用 3 层网络, 其输入层结点数为 7, 隐含层结点数为 4, 迭代上限 2000 次。网格搜索法对参数 C 、 ε 、 σ 的取值区间划分为 100, 则共需 10^6 次寻优; GA-SVM 模型的规模和迭代次数与 CFPSO-SVM 相同。模型预测对比结果见表 4。

表 4 不同模型预测值和实际值

Tab.4 Predicted values of different models and measured values

Measured values/(mm·a ⁻¹)	BPNN		SVM		GA-SVM		CFPSO-SVM	
	Predicted values/(mm·a ⁻¹)	Error/%	Predicted values/(mm·a ⁻¹)	Error/%	Predicted values/(mm·a ⁻¹)	Error/%	Predicted values/(mm·a ⁻¹)	Error/%
0.2282	0.3203	40.36	0.2483	8.81	0.2246	-1.58	0.2269	-0.57
0.1853	0.2265	22.23	0.1732	-6.53	0.1524	-17.75	0.1732	-6.53
0.2052	0.1772	-13.65	0.2398	16.86	0.2261	10.19	0.1817	-11.45
0.3762	0.4954	31.69	0.4023	6.94	0.3618	-3.83	0.3659	-2.74
0.2782	0.1826	-34.36	0.2565	-7.80	0.2654	-4.60	0.2748	-1.22
0.0507	0.0338	-33.24	0.0527	3.93	0.0549	8.21	0.0496	-2.14
0.1904	0.1467	-22.95	0.1989	4.49	0.1973	3.64	0.1923	1.01
0.2867	0.2003	-30.14	0.2999	4.59	0.2894	0.93	0.2856	-0.38
0.1854	0.2054	10.83	0.1918	3.45	0.1957	5.55	0.1847	-0.37
0.1788	0.1642	-8.14	0.1662	-7.05	0.1732	-3.14	0.1820	1.81

从表 4 可知, BP 神经网络模型预测结果整体误差最大, 与其他预测模型相比, 误差结果高了一个数量级, 这表明 BP 模型容易陷入局部极值的缺陷。相

对于 BP 模型, 网格搜索优化 SVM 和 GA-SVM 网络模型的预测精度有了较大的提高, 平均相对误差分别为 7.04% 和 5.94%。其中, GA-SVM 模型的寻优次数

远小于网格搜索 SVM, 且能够发挥遗传算法的全局寻优能力。CFPSO-SVM 的平均相对误差最小, 为 2.82%, 相比于 GA-SVM 模型, CFPSO-SVM 除了具有全局寻优能力, 还有高效的信息共享机制, 因此收敛速度更快, 同时编程实现方式也更简单。

考虑到数据的随机性误差, 将预测值与实际测量值进行相关性分析, 结果如图 4。通过计算求得各模型预测结果与测量值的相关系数 R 值分别为: $R_{BPNN}=0.8234$ 、 $R_{SVM}=0.9820$ 、 $R_{GA-SVM}=0.9845$ 、 $R_{CFPSO-SVM}=0.9955$, R 取值[0,1]。其中, R 值越接近 1, 表明模型的预测结果越接近实际值。因此可以看出, CFPSO-SVM 的预测效果最优。




图 4 预测值和测量值的相关性

Fig.4 Correlations of predicted values and measured values

6 结论

1) 通过主成分分析, 得到对内腐蚀有主要贡献的 7 个因素: H_2S 、 CO_2 、 Cl^- 含量、酸碱值、压力、介质温度、流速。这 7 个因素能够最大程度地反映出形成内腐蚀的原因, 并将其作为 SVM 预测模型的输入参数。

2) 利用鲈鱼粒子群算法优化影响 SVM 预测精度的参数, 能够避免陷入局部极值的问题。在相同寻优次数下, CFPSO 的收敛速度快于 GA 算法, 并且 CFPSO 的参数寻优次数为 10^4 , 远低于网格交叉 SVM 的 10^6 次。

3) 与实测值相比, CFPSO-SVM 对管道内腐蚀的预测结果平均相对误差为 2.82%, 相关度为 0.9955, 效果优于经常使用的 BP 神经网络、网格交叉 SVM 和遗传算法优化 SVM 模型。这为及时准确掌握管道腐蚀情况和进一步估算金属管道寿命提供了可靠依据, 也为管道的维修策略提供了参考。

参考文献:

[1] 张清玉. 油气田工程实用防腐技术[M]. 北京: 中国石化出版社, 2009.

ZHANG Qing-yu. Oil and gas field engineering practical anticorrosion technology[M]. Beijing: China Petrochemical Press, 2009.

- [2] 柯伟. 中国工业与自然环境腐蚀调查的进展[J]. 腐蚀与防护, 2004, 25(1): 1-8.
KE Wei. Progress in the investigation of the corrosion of China's industrial and natural environment[J]. Corrosion and protection, 2004, 25(1): 1-8.
- [3] 张伟刚, 赵会军, 张璇, 等. X80 管线钢在含硫原油中的顶部腐蚀行为[J]. 腐蚀与防护, 2016, 37(8): 623-626.
ZHANG Wei-gang, ZHAO Hui-jun, ZHANG Xuan, et al. Top-of-line corrosion behavior of X80 pipeline steel in sour crude[J]. Corrosion and protection, 2016, 37(8): 623-626.
- [4] 张弦, 杨森, 汪新, 等. 低碳钢在 H_2S 溶液中的腐蚀行为研究[J]. 中国腐蚀与防护学报, 2010, 30(6): 465-468.
ZHANG Xian, YANG Miao, WANG Xin, et al. Corrosion behavior of mild steel under condition of H_2S solution[J]. Journal of Chinese society for corrosion and protection, 2010, 30(6): 465-468.
- [5] 方晓君, 彭伟华, 李建东, 等. 温度、流速及压力对原油腐蚀性的影响[J]. 腐蚀科学与防护技术, 2014, 36(5): 431-435.
FANG Xiao-jun, PENG Wei-hua, LI Jian-dong, et al. Influence of temperature, flow velocity and pressure on corrosion of crude oil[J]. Corrosion science and protection technology, 2014, 36(5): 431-435.
- [6] BEEN J, HOLM M. Evaluating corrosion and inhibition under sludge deposits in large diameter crude oil pipelines[J]. Journal of the electrochemical society, 2010, 162(10): 491-496.
- [7] YORDAN G, SMILJKO R, CARLOS G S. Fatigue damage of structural joints accounting for nonlinear corrosion[J]. Journal of ship research, 2002, 46(4): 289-298.
- [8] HOFFMEISTER H. Modeling of hydrogen sulfide corrosion by coupling of phase and polarization behavior[J]. Corrosion, 2006, 62(12): 1092-1099.
- [9] 付秀勇, 徐久龙, 李军, 等. 凝析气田集输管道的冲刷腐蚀与防护[J]. 石油化工腐蚀与防护, 2008, 25(2): 20-23.
FU Xiu-yong, XU Jiu-long, LI Jun, et al. Erosion-corrosion of gathering pipelines in condensate gas field[J]. Corrosion and protection in petrochemical industry, 2008, 25(2): 20-23.
- [10] OKABE S, ITO T, SATORHE H. Sulfate-reducing bacterial community structure and their contribution to carbon mineralization in a wastewater biofilm growing under microaerophilic conditions[J]. Applied microbiology biotechnology, 2003, 63(3): 322-334.
- [11] 赵海霞, 武建. 浅析主成分分析方法[J]. 科技信息, 2009(2): 87.

- ZHAO Hai-xia, WU Jian. Analysis of principal component analysis[J]. Science and technology information, 2009(2): 87.
- [12] 范雪莉, 冯海泓, 原猛. 基于互信息的主成分分析特征选择算法[J]. 控制与决策, 2013, 27(6): 915-919.
FAN Xue-li, FENG Hai-hong, YUAN Meng. PCA based on mutual information for feature selection[J]. Control and decision, 2013, 27(6): 915-919.
- [13] 高惠璇. 应用多元统计分析[M]. 北京: 北京大学出版社, 2005.
GAO Hui-xuan. Application of multivariate statistical analysis[M]. Beijing: Peking University Press, 2005.
- [14] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 34-42.
ZHANG Xue-gong. Introduction to statistical learning theory and support vector machines[J]. Acta automatica sinica, 2000, 26(1): 34-42.
- [15] 葛海峰, 林继鹏, 刘君华, 等. 基于支持向量机和小波分解的气体识别研究[J]. 仪器仪表学报, 2006, 27(6): 573-578.
GE Hai-feng, LIN Ji-peng, LIU Jun-hua, et al. Gas identification based on support vector machine and wavelet decomposition[J]. Chinese journal of scientific instrument, 2006, 27(6): 573-578.
- [16] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. Neural network letters, 1999, 19(3): 293-300.
- [17] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995: 52-123.
- [18] 陈圣兵, 王晓峰. 基于样本差异度的 SVM 训练样本缩减算法[J]. 计算机工程与应用, 2012, 48(7): 20-22.
CHEN Sheng-bing, WANG Xiao-feng. Algorithm for reduction SVM training sample based on sample dissimilarity[J]. Computer engineering and applications, 2012, 48(7): 20-22.
- [19] 易文周. 混沌鲶鱼粒子群优化和差分进化混合算法[J]. 计算机工程与应用, 2012, 48(15): 54-58.
YI Wen-zhou. Hybrid algorithm of chaotic catfish particle swarm optimization and differential evolution[J]. Computer engineering and applications, 2012, 48(15): 54-58.
- [20] 胡旺, GARY G Y, 张鑫. 基于 Pareto 熵的多目标粒子群优化算法[J]. 软件学报, 2014, 25(5): 1025-1050.
HU Wang, GARY G Y, ZHANG Xin. Multiobjective particle swarm optimization based on pare to entropy[J]. Journal of software, 2014, 25(5): 1025-1050.
- [21] CHUANG L Y, TSAI S W, YANG C H. Chaotic catfish particle swarm optimization for solving global numerical optimization problems[J]. Applied mathematics and computation, 2011, 217(16): 6900-6916.
- [22] HOTEIT H, BANKI R, FIROOZABADI A. Wax deposition and aging in flow lines from irreversible thermodynamics[J]. Energy and fuels, 2008, 22(4): 2693-2706.