

基于改进的KPCA-PSO-WLSSVM在循环水腐蚀预测中的应用

针对石化现场腐蚀速率参数存在测量成本高、测量周期长的问题,结合国内外腐蚀研究现状提出了一种基于改进的自适应加权最小二乘支持向量机回归建模方法。该方法首先对数据进行整合处理,借助核主成分分析(KPCA)算法对整合后的数据进行主成分提取,依据处理好的数据建立LS-SVM模型;其次采用改进的加权算法对LS-SVM进行权值处理;然后采用全局搜索能力较强的混沌粒子群-模拟退火优化算法(CPSO-SA)对LS-SVM模型正则化参数和核宽度参数进行优化,提高模型的泛化能力;最后建立优化后的KPCA-WLS-SVM模型。实验结果表明,应用该方法建立的循环水腐蚀预测模型的预测准确度远远高于其他预测模型的预测准确度。

秦雯/兰州工业学院

0 引言

腐蚀预测过程是工业循环冷却水处理过程中的重要环节。因工业循环冷却水处理过程复杂多变,影响循环水冷却效率的腐蚀速率,难以实现在线检测,给循环冷却水处理过程的实时控制和优化操作带来了很大的不便。本文将软测量技术应用于循环冷却水腐蚀处理过程,建立循环水腐蚀预测模型是解决这一难题的有效途径。

目前,腐蚀参数预测的方法有神经网络、灰色系统理论和回归分析等方法。因神经网络具有强大的非映射能力,在腐蚀预测时得到了广泛应用^[1-3]。但是神经网络存在泛化能力差、对样本数据要求严格的弊端,而支持向量机具有较强的泛化能力,克服了神经网络的缺陷,

因此在处理非线性和高维数问题方面具有较强的优势。国内外学者利用支持向量机(SVM)在循环水领域进行了大量的预测实验^[4],其中以最小二乘支持向量机(LS-SVM)^[5]预测效果最为有效,LS-SVM同SVM相比,虽然计算能力有所提升,但是比鲁棒性能变差。

针对工业现场运行过程中仪表损坏、非计划停车等问题,现场来源数据存在误差过大或缺失,使得依据现场数据建立的预测模型准确度过于低下。为了解决因样本数据导致模型预测性能下降的问题,本文利用数据整合处理方法和核主成分分析(KPCA)方法对样本数据进行清洗主成分提取,依据样本数据建立最小二乘支持向量机(LS-SVM)预测模型。但是LS-SVM算法的目标函数采用误差均方和的形式,降低了模型的鲁棒性,本文采用改进的权值处理方法建立了加权最小二乘支持向量机模型^[6],同时由于其正则化参数和核宽度参数对模型预测准确度影响较大^[7],故采用混沌粒子群-模拟退火优化算法(CPSO-SA)对这两类参数进行优化选取,以提取适合模型的最佳参数。最后以某石化企业的循环冷却水处理参数为例检验KPCA-WLS-SVM算法在腐蚀参数预测中的有效性。

1 基于数据整合的KPCA-WLSVM算法

1.1 核主成分分析(KPCA)

主成分分析(PCA)是将数据从高



秦雯/讲师

关键词/Keywords

核主元分析算法·
循环冷却水·
腐蚀预测·

维投影到低维,用极少的主成分来代替大部分的数据信息。但是PCA法只适用于线性分析,在工业循环冷却水处理过程中,其大部分的数据呈非线性关系,故此引入KPCA方法,在保证数据信息不丢失的原则下,对数据进行降维处理,提取主成分信息。

假设样本数据 x_k ($k=1, 2, \dots, l$) 进行非线性变换 $\Phi(x_k)$, 变换公式如下

$$C = \frac{1}{l} \sum_{j=1}^l \Phi(x_j) \Phi(x_j)^T \quad (1)$$

式中的特征值和特征向量满足

$$\lambda V = CV \quad (2)$$

两边同时乘以 $\Phi(x_k)$, 得到

$$\lambda \Phi(x_k) V = \Phi(x_k) C V \quad (3)$$

对 $\lambda \neq 0$ 的所有特征向量 V , 有

$$V = \sum_{i=1}^l \alpha_i \Phi(x_i) \quad (4)$$

引入核函数 K_{ij} , 得到

$$K_{ij} = K(x_i, x_j) = \Phi(x_i) \Phi(x_j)^T \quad (5)$$

如果求解核矩阵 K 的特征值和特征向量得到

$$l \lambda \alpha = K \alpha \quad (6)$$

对于任意向量 x , 在特征空间主元方向 $\Phi(x)$ 上的投影为

$$V \Phi(x_i) = \sum_{i=1}^l \alpha_i \Phi(x_i) \Phi(x_i)^T = \sum_{i=1}^l \alpha_i K(x_i, x) \quad (7)$$

主元数量 s 的一般选取规则为

$$\left| \frac{\sum_{k=1}^s \lambda_k}{\sum_{k=1}^l \lambda_k} \right| > E \quad (8)$$

式中, E 在工程上一般取值为85%。

本文选取径向基核函数作为KPCA算法的核函数, 其表达式为

$$K(x_i, x_j) = \exp \left[-\frac{|x_i - x_j|^2}{2\sigma^2} \right] \quad (9)$$

1.2 最小二乘支持向量机 (LS-SVM)

支持向量机 (SVM) 作为一种较新算法, 因其具有比神经网络更优越的性能而被广泛使用。但是SVM在训练大样本数据时, 其学习过程消耗时间也随之增大。为提高算法的求解速度, 最小二乘支持向量机 (LS-SVM) 被提出。LS-SVM是SVM的一种拓展, 其核心思想是将误差的二范数定义为损失函数, SVM的不等式约束改为等式约束而降低模型运算复杂度。假设给定训练集合 $\{(x_i, y_i) | i=1, 2, \dots, N\}$, 其中, $x_i \in R^d$ 为维训练样本输入, 为训练样本输出, 优化问题可描述为^[8-9]

$$\min \frac{1}{2} \omega^T \omega + \frac{1}{2} C \sum_{i=1}^N \xi_i^2 \quad (10)$$

$$\text{s.t. } y_i = \omega^T \varphi(x_i) + b + \xi_i \quad (11)$$

式中, ω 为权系数向量; $\varphi(\cdot)$ 为输入空间到高维空间的映射; C 为正则化参数; ξ_i 为拟合误差; b 为阈值。

根据式 (10) 的优化目标函数, 定义拉格朗日函数为

$$L(\omega, b, \xi, \alpha) = \frac{1}{2} \omega^T \omega + \frac{1}{2} C \sum_{i=1}^N \xi_i^2 - \sum_{i=1}^N \alpha_i [\omega^T \varphi(x_i) + b + \xi_i - y_i] \quad (12)$$

式中, α_i ($i=1, 2, \dots, N$) 为拉格朗日乘子, 根据KKT (Karush-Kuhn-Tucker) 条件得到

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \omega - \sum_{i=1}^N \alpha_i \varphi(x_i) = 0 \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \rightarrow \alpha_i = C \xi_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \omega^T \varphi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (13)$$

消去变量 ω 、 ξ_i , 并引入核函数

$$K(x_i, x_j) = \varphi^T(x_i) \varphi(x_j) \quad (14)$$

可得矩阵方程

$$\begin{bmatrix} 0 & I_{1 \times N} \\ I_{N \times 1} & R + \frac{1}{C} E \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (15)$$

式中, $l_{1 \times N}$ 为 $1 \times N$ 的单位向量; $l_{N \times 1}$ 为 $N \times 1$ 的单位列向量; $R = \{K(x_i, x_j) | i, j = 1, 2, \dots, N\}$; E 为 $N \times N$ 单位矩阵; $y = [y_1, y_2, \dots, y_N]^T$; $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$ 。

式(15)方程可用最小二乘法求得 b 和 a , 最终得到回归函数的形式如下

$$y = \sum_{i=1}^N \alpha_i K(x_i, x) + b \quad (16)$$

1.3 加权最小二乘支持向量机 (WLS-SVM)

LS-SVM 虽然降低了运算复杂度, 但也降低了 SVM 的稀疏性。WLS-SVM 的核心思想是在 LS-SVM 的基础上对训练误差赋予权值, 以避免 LS-SVM 目标函数采用误差均方和导致模型的鲁棒性能下降的问题。表达式如下

$$\min \frac{1}{2} \omega^T \omega + \frac{1}{2} C \sum_{i=1}^N v_i \xi_i^2 \quad (17)$$

$$\text{s.t. } y_i = \omega^T \varphi(x_i) + b + \xi_i \quad (18)$$

定义拉格朗日函数为

$$L(\omega, b, \xi, \alpha^*) = \frac{1}{2} \omega^T \omega + \frac{1}{2} C \sum_{i=1}^N \xi_i^2 - \sum_{i=1}^N \alpha_i^* [\omega^T \varphi(x_i) + b + \xi_i - y_i] \quad (19)$$

式中, $\alpha^* (i=1, 2, \dots, N)$ 为拉格朗日乘子。根据上式目标函数以及 KKT 条件, 推导出矩阵方程

$$\begin{bmatrix} 0 & l_{1 \times N} \\ l_{N \times 1} & R + \frac{1}{C} E \end{bmatrix} \begin{bmatrix} b \\ \alpha^* \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (20)$$

式中, 对角矩阵 $V = \text{diag}(v_1^{-1}, v_2^{-1}, \dots, v_N^{-1})$, v_N 为权值变量; $\alpha^* = [\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*]^T$, 其他参数不变。最终得到回归函数方程为

$$y = \sum_{i=1}^N \alpha_i^* K(x_i, x) + b \quad (21)$$

WLS-SVM 在建模过程中考虑了样本误差对模型造成的影响, 通过比较模型的拟合误差大

小, 确定不同建模样本的权重。文献[10]提出的加权最小二乘支持向量机, 其权值表达式如下

$$v_i = \begin{cases} 1 & \left| \frac{\xi_i}{\hat{s}} \right| \leq s_1 \\ 10^{-4} & \text{Otherwise} \\ \frac{s_2 - \left| \frac{\xi_i}{\hat{s}} \right|}{s_2 - s_1} & s_1 \leq \left| \frac{\xi_i}{\hat{s}} \right| \leq s_2 \end{cases} \quad (22)$$

式中, s_1 和 s_2 根据样本误差的大小分布确定, 一般选取 $s_1 = 2.5$, $s_2 = 3$; $\hat{s}$ 为 LS-SVM 的样本误差 ξ_i 的标准方差的鲁棒估计, 即

$$\hat{s} = \frac{\text{IQR}}{2 \times 0.6745} \quad (23)$$

式中, IQR 为样本误差 ξ_i 的四分位差。

但是文献[10]提出的权值判断是基于线性环境下的, 本文研究的循环水腐蚀过程是非线性的问题。基于上述问题本文构建新的权值计算公式为

$$\hat{s} = \frac{1}{(1 + \left| \frac{e_i}{2\hat{s}} \right|)^2} \quad (24)$$

样本数据中存在的误差数据值越大, 所占的权值比重越小, 误差数据对模型准确度的影响程度越低。

1.4 混沌粒子群-模拟退火优化算法 (CPSO-SA)

通过诸多文献证明, LS-SVM 的正则化参数和核宽度是影响模型建模效果的两类参数。本文通过采用一种混沌粒子群-模拟退火算法 CPSO-SA)^[11] 对 LS-SVM 模型的参数进行优化选择。

算法的关键步骤如下。

1) 建立目标优化函数, 即

$$\min_{C, \sigma} J = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (25)$$

$$\text{s.t. } \begin{cases} C_{\min} \leq C \leq C_{\max} \\ \sigma_{\min} \leq \sigma \leq \sigma_{\max} \end{cases} \quad (26)$$

式中, y_i 为样本的实际值; $\hat{y}_i$ 为预测模型的预测值。

2) 设置种群规模为 m , 最大迭代次数 $t=t_{\max}$, 初始化温度 $T=T_0$, 终止温度 $T=T_{\text{end}}$, 随机产生 m 个粒子, 即 $\{P_1, P_2, \dots, P_m\}$, 初始化粒子群参数。

3) 根据粒子的位置 p_{id}^t 及其速度 u_{id}^t , 计算出每一个粒子的适应度 $f(P_i)$ 值, 确定出最佳粒子 $P_{\text{best}}^{[12]}$, 根据式 (11) 对 P_{best} 进行 M 次迭代, 得到混沌变量序列 $\{P_{\text{best}}^1, P_{\text{best}}^2, \dots, P_{\text{best}}^m\}$, 即

$$p^{(n+1)} \leftarrow \lambda p^n (1 - p^n) \quad (27)$$

4) 根据PSO优化原则, 更新粒子的位置 p_{id}^t 及其速度 u_{id}^t , 获得全局最优粒子 P_{best}^* 。

5) 根据SA原则截取全局最优粒子 P_{best}^* 的一个领域值 $\hat{P}_{\text{best}}^*$, 即

$$f = f(\hat{P}_{\text{best}}^*) - f(P_{\text{best}}) \quad (28)$$

如果 $\Delta f < 0$, 则更新 P_{best}^* ; 否则令 $s = \exp(-\Delta f/T)$ 。如果 $s > \text{rand}(0, 1)$, 则更新 P_{best}^* ; 如果 $s \leq \text{rand}(0, 1)$, P_{best}^* 不变。

6) 根据温度下降函数 $T=T(t)$, 更新温度 T , 如果温度 $T < T_{\text{end}}$, 迭代终止输出最优正则化参数 C 和核宽度参数 σ , 否则返回步骤5)。

2 基于KPCA-PSO-WLSSVM的循环水腐蚀速率参数估计

2.1 数据整合

1) 误差处理。利用 3δ 原则对存在明显误差的数据进行处理。

2) 插值填补。原始样本数据经过上述步骤的数据清洗, 剔除了原有的误差数据, 但也导致了样本数据在此周期内的数据缺失问题。本文拟采用中位值填补法对该周期内的数据进行填补, 在最大程度上对缺失数据进行填补。中位值填补法最重要的是能够将缺失数据前后的两个数据取其中间值, 因此能够获取该周期内最接近现场数据的信息。

3) 归一化处理。因数据采集单位、量值不同, 需对数据进行统一处理。本文通过对比极大化处理、极小化处理、初值处理和均值化处理结果, 最终采用均值化公式对数据进行无量纲化处理, 具体如下

$$X_i'(t) = X_i(t) / \bar{X} \quad (29)$$

式中, $X_i'(t)$ 为均值化后的数据; $X_i(t)$ 为原始数据; $\bar{X}$ 为原始数据的均值。

2.2 预测模型总体结构图

预测模型总体结构如图1所示。




图1 预测模型总体结构

综上所述，KPCA-WLS-SVM预测模型的建模步骤如下：

- 1) 整合数据，应用KPCA算法对整合后的数据进行主成分提取。
- 2) 利用提取后的主成分建立LS-SVM预测模型。
- 3) 运用混沌粒子群-模拟退火算法对LS-SVM模型的正则化参数和核宽度参数择优选取，并通过改进的权值计算方法对LS-SVM的权值进行选取，最终建立优化后的KPCA-WLS-SVM预测模型。
- 4) 利用优化后的KPCA-WLS-SVM预测模型进行腐蚀预测。

3 实例分析

图2为某石化企业的循环冷却水系统流程工艺简图。工艺生产设备经过长时间的运行，导致设备温度较高，换热器通过冷却水对生产设备进行降温，换热后的冷却水进入冷却塔经过风机冷却进入冷水池，根据冷水池水质的指标对冷却水投放药剂，补充新鲜水等办法使集水池的冷却水成为标准的冷却介质，然后经由泵网输送到冷却系统继续循环利用。

在冷却水循环过程中，受管道泄漏以及微生物滋生造成腐蚀问题的影响，使得换热器管道内壁变薄，影响换热效率。




图2 循环冷却水流程简图

本文选取某石化企业从2002年开始至今的部分现场数据作为验证WLS-SVM模型的有效数据。这些现场数据来自于不同的部门，每个部门各整理出190 046个数据。表1为与腐蚀相关的水质参数。

表1 水质参数

参数	名称	参数	名称	参数	名称
X_1	浓缩倍数	X_6	COD(mg/L)	X_{11}	钾离子(mg/L)
X_2	浊度(mg/L)	X_7	电导率(μ s/cm)	X_{12}	钙离子(mg/L)
X_3	余氯(mg/L)	X_8	总铁(mg/L)	X_{13}	氯离子(mg/L)
X_4	总磷(mg/L)	X_9	总碱(mg/L)	X_{14}	细菌
X_5	正磷(mg/L)	X_{10}	生物粘泥	X_{15}	pH值

本文所用数据均来源于现场，难免存在各种误差，借用上述提到的数据整合处理方法对这些数据进行清洗整合。将处理后的数据按照4:1的比例进行测试集和预测集预测。通过KPCA算法对样

本数据进行分析降维，再将数据进行分析后得到特征值贡献率如表2所示。

表2 特征值的贡献率

序号	合计	贡献率(%)	累计贡献率(%)
1	7.852	52.342	52.342
2	1.79	11.869	64.211
3	1.418	9.462	73.673
4	1.14	7.615	81.289
5	0.97	6.541	90.563
6	0.728	4.864	92.604
7	0.526	3.445	96.049
8	0.381	2.561	98.623
9	1.136	0.905	99.514
10	0.039	0.263	99.777
11	0.03	0.131	99.908
12	0.008	0.059	99.968
13	0.004	0.032	99.999
14	0.000 072 28	0	100
15	0.000 222 7	0	100

由表2可以看出,第5个主成分的特征值累积贡献率超过90%,第7个主成分的特征值累积贡献率超过95%。一般来说,只要特征值的累计贡献率超过90%即可,为了保证预测准确度,选取前6个主成分作为样本输入数据。


将KPCA降维后的主成分作为预测模型的输入数据,对取定的训练样本和测试样本分别采用加权最小二乘支持向量机(WLS-SVM)、粒子群支持向量机(PSO-WLSSVM)、基于主元分析的粒子群支持向量机(PCA-PSO-WLSSVM)以及基于核主元分析的粒子群支持向量机(KPCA-PSO-WLSSVM)进行预测。在建模过程中,WLS-SVM模型的正则化参数 C 和核宽度参数 σ 分别取值为10和 $1.5^{[14]}$ 。为了更好地比较其他三个模型的预测结果,均设置其种群规模 $m=40$,最大迭代次数 $t_{\max}=300$,初始温度 $T_0=150$,终止温度 $T_{\text{end}}=5$,冷却速率 $\rho=0.8$ 。图3为利用四种建模方法对试验集数据进行预测得到的结果;图4为利用四种建模方法对测试集数据进行预测得到的结果。

通过对比图3和图4可以看出,图4中WLS-SVM预测模型和PSO-WLSSVM预测模型的预测结果与真实数据进行对比具有很明显的误差,

虽然PCA-PSO-WLSSVM预测模型和KPCA-PSO-WLSSVM预测模型的预测结果与真实数据结果比较接近,但是KPCA-PSO-WLSSVM预测模型的预测结果明显比PCA-PSO-WLSSVM的预测结果更加真实。为了直观地看出四种建模方法的预测结果,采用绝对误差的方式给出了四种建模方法的预测结果绝对误差值,如图5所示。从图5中可以看出,KPCA-PSO-WLSSVM预测模型的预测结果绝对误差在 $-0.01\sim 0.01$ 之间进行波动,而其他三种模型的绝对误差则相对较大。由此可以表明采用KPCA-PSO-WLSSVM建立的预测模型,其预测准确度明显高于其他三种建模方法。

4 结束语

针对现场采集数据存在过多的误差或数据缺失导致模型性能下降的问题,本文通过数据整合处理技术对数据进行剔除、填补和归一化处理等,以保证数据的完整性。同时采用KPCA对数据进行降维,节省了计算资源。在支持向量机的基础上对算法进行优化组合,形成了混沌粒子群-模拟退火(CPSO-SA)优化WLS-SVM算法。






图4 测试集预测结果对比




图5 模型预测结果绝对误差图

通过对循环冷却水处理工艺进行机理分析,利用现场车间的实测数据,并利用该算法建立了循环水腐蚀速率预测模型,与加权最小二乘支持向量机(WLS-SVM)、粒子群支持向量机(PSO-WLSSVM)、基于主元分析的粒子群支持向量机(PCA-PSO-WLSSVM)以及基于核主元分析的粒子群支持向量机(KPCA-PSO-WLSSVM)进行结

果对比,结果表明通过此方法建立的循环水腐蚀预测模型与其他预测模型相比预测准确度更高,能够为循环冷却水的腐蚀预测提供精准的参考。

参考文献

- [1] 喻西崇,赵金洲,吴应湘,等.利用改进的神经网络预测腐蚀管道的剩余强度[J].压力容器,

- 2003(10): 22-27.
- [2] 李亚峰, 陶翠翠, 蒋白懿, 等. 改进BP神经网络预测埋地金属给水管道外腐蚀速率的研究[J]. 给水排水, 2010, 46(增刊1): 440-442.
- [3] 董超, 胡艳珍, 李晨光. 基于改进的T-S模糊神经网络循环冷却水腐蚀预测[J]. 化工自动化及仪表, 2018, 45(1): 51-55.
- [4] 战越, 宋志刚, 王海莹. 用SVM预测稀硫酸对透水混凝土的腐蚀[J]. 价值工程, 2017, 36(1): 91-92.
- [5] 骆正山, 毕傲睿, 王小完. 基于PCA-SVM的高含硫油气混输管道腐蚀预测[J]. 中国安全科学学报, 2016, 26(2): 85-90.
- [6] 何敏. 炼油装置循环水换热系统腐蚀模型与评价研究[D]. 西安: 西安石油大学, 2014.
- [7] Alireza Baghban, Mohammad Navid Kardani, Sajjad Habibzadeh. Prediction viscosity of ionic liquids using a hybrid LSSVM and group contribution method[J]. Journal of Molecular Liquids, 2017, 236: 452-464.
- [8] Hamidreza Yarveicy, Mohammad M Ghiasi. Modeling of gas hydrate phase equilibria: Extremely randomized trees and LSSVM approaches[J]. Journal of Molecular Liquids, 2017, 243: 533-541.
- [9] 龙文, 焦建军, 龙祖强. 基于PSO优化LSSVM的未知模型混沌系统控制[J]. 物理学报, 2011, 60(11): 120-125.
- [10] Suykens J A K, Vandewalle J. Least squares support vector machines classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [11] Sheng Hanlin, Zhang Tianhong. Aircraft engine thrust estimator design based on GSA-LSSVM[J]. International Journal of Turbo & Jet-Engines, 2017, 34(3).
- [12] Ma Liang, Liu Xinggao. A novel APSO-aided weighted LSSVM method for nonlinear hammerstein system identification[J]. Journal of the Franklin Institute, 2017, 354(4): 1892-1906.
- [13] Gorjaei R G, Songolzadeh R, Torkaman M, et al. A novel PSO-LSSVM model for predicting liquid rate of two phase flow through wellhead chokes[J]. Journal of Natural Gas Science and Engineering, 2015, 24: 228-237.
- [14] Gao Junwei, Leng Ziwen, Qin Yong, et al. Application of GA-LSSVM in fault diagnosis of subway auxiliary inverter[M]. Berlin Heidelberg: Springer, 2014.

(收稿日期: 2018-05-26)EA

机械工业信息研究院
机械工业出版社

全媒体传播平台
EA Multi-media Platform

期刊 Magazine	会议 Events	活动 Activity
微信 WeChat	数字 Digital	服务 Service

用新电气化改变世界
Change the world with new electrification

电气时代杂志社
Electric Magazine Agency

电力电网
Power grid

轨道交通
Rail transportation

新能源
New energy

石油化工
Petrochemical

基础设施
Infrastructure

智慧工厂
Factory automation

电话: (+86 10) 88379054 传真: (+86 10) 68994786
地址: 北京市西城区百万庄大街22号 邮编: 100037
邮箱: info@eage.com.cn 网址: www.eage.com.cn