

doi: 10.7690/bgzd.2026.01.011

# 基于 KPCA-HDBO-KELM 的装备金属结构件腐蚀速率预测

孙伟赫, 洪 亮, 赵建印

(海军航空大学岸防兵学院, 山东 烟台 264000)

**摘要:** 针对腐蚀导致装备可靠性降低、战斗力减弱的问题, 提出基于核极限学习机(kernel extreme learning machine, KELM)的装备结构件腐蚀速率预测模型。采用核主成分分析(kernel principal component analysis, KPCA)对原始数据进行预处理, 再采用改进混合蜣螂优化(hybrid dung beetle optimizer, HDBO)算法对 KELM 中核参数和正则化系数进行寻优, 引入 Singer 混沌映射改进蜣螂种群初始化分布位置; 采用可变螺旋搜索策略改进产卵蜣螂和觅食蜣螂觅食位置更新过程, 扩展蜣螂探索未知区域的能力; 引入 Levy 飞行策略和自适应权重, 增强算法的全局搜索和局部寻优能力。构建 KPCA-HDBO-KELM 装备金属结构件腐蚀速率预测模型。使用 60 组装备金属结构件腐蚀速率实验数据进行验证, 并与其余 3 个模型对比。结果表明: KPCA-HDBO-KELM 模型预测结果较其余模型更精准、稳定性更好, 且 MSE、MAE 指标均优于对比模型, 在预测装备结构件腐蚀速率方面具有较高的稳定性和精度。

**关键词:** 装备; 腐蚀速率; HDBO; KELM**中图分类号:** TP301.6; TG172.5 **文献标志码:** A

## Corrosion Rate Prediction of Equipment Metal Structure Based on KPCA-HDBO-KELM

Sun Weihe, Hong Liang, Zhao Jianyin

(School of Coastal Defense, Naval Aviation University, Yantai 264000, China)

**Abstract:** Aiming at the problem that the reliability and combat effectiveness of equipment are reduced due to corrosion, a corrosion rate prediction model for equipment components based on kernel extreme learning machine (KELM) is proposed. The kernel principal component analysis (KPCA) was used to preprocess the original data, and then the improved hybrid dung beetle optimization (HDBO) algorithm was used to optimize the kernel parameters and regularization coefficients in KELM, and the Singer chaotic map was introduced to improve the initial distribution position of dung beetle population; A variable spiral search strategy was used to improve the foraging position update process of the spawning dung beetle and foraging dung beetle, and to expand the ability of the beetle to explore the unknown area. Levy flight strategy and adaptive weight were introduced to enhance the global search and local optimization ability of the algorithm. The corrosion rate prediction model of KPCA-HDBO-KELM equipment was established. Sixty groups of experimental data of corrosion rate of equipment metal structures were used to verify and compare with the other three models. The results show that the KPCA-HDBO-KELM model is more accurate and stable than other models, and the MSE and MAE indicators are better than comparison model, which has high stability and accuracy in predicting the corrosion rate of equipment components.

**Keywords:** equipment; corrosion rate; HDBO; KELM

### 0 引言

东南沿海(岛礁)地区恶劣的服役环境使装备出现严重的腐蚀、霉变等质量问题, 降低了装备可靠性水平, 制约装备作战性能的发挥。较其他大气环境而言, 金属材料在海洋大气中的腐蚀速率为内陆大气腐蚀的 2~5 倍<sup>[1-2]</sup>, 岛礁高温、高湿、高盐雾的恶劣环境给装备造成强烈的腐蚀问题, 不仅会导致装备外表损坏、零部件锈蚀老化、机械强度降低、使用寿命缩短, 而且有些零部件甚至会出现裂纹或脆性断裂<sup>[3]</sup>, 严重影响装备的服役期限、可靠性和技战术性能; 因此, 实现对装备腐蚀速率的精

准预测, 掌握腐蚀规律, 对提升装备维修性水平尤为重要。

目前, 在腐蚀速率问题研究方面比较常见的预防方法有灰色理论模型、幂函数模型、机器学习法等, 文献[4]采用粒子群算法优化 MGM(1, 1)模型, 实现对管道腐蚀速率预测; 文献[5]建立了基于灰色模型的尾段残差修正 GM(1, 1)模型, 对管道剩余寿命预测精度较高; 文献[6]将灰色理论与随机森林算法相结合, 建立的模型用于管道腐蚀速率预测, 模型鲁棒性较高。以上改进的模型虽然预测精度较高, 但都是基于灰色理论 GM(1, 1)模型预测的, 该

收稿日期: 2024-11-10; 修回日期: 2024-12-15

第一作者: 孙伟赫(1995—), 男, 山东人, 硕士。

模型抗扰动性较差且仅考虑单一因素影响，装备服役期间的腐蚀影响因素众多，所以并不适用于此次研究。在面向多输入变量的腐蚀速率研究方面，文献[7]利用因子分析对数据进行降维，使用 CS 算法优化极限学习机(extreme learning machine, ELM)对埋地管道腐蚀速率进行预测；文献[8]采用多种群甲虫天牛须优化算法(multiple beetle antennae search, MBAS)优化 ELM 对海底管道内腐蚀速率进行预测，模型在数据较少的情况下有较好的鲁棒性。ELM 模型虽然训练速度快、泛化效果好，但模型稳定性较差且非线性表示能力弱。综上所述，笔者以装备腐蚀速率为研究对象，提出 KPCA-HDBO-KELM 腐蚀速率预测模型。利用核主成分分析(KPCA)提取影响装备腐蚀的主要因素，采用核函数改善 ELM 性能，采用混合蜣螂优化(HDBO)算法对核极限学习机(KELM)中的核参数和正则化系数进行寻优，进一步提高模型的精度和稳定性。同时，根据装备金属结构件腐蚀速率实验数据进行验证分析。分析结果表明，建立的模型对装备腐蚀速率预测精度较高。

1 沿海地区装备腐蚀问题分析

持续高温、高湿、高盐雾和霉菌的综合应力作用是海洋大气环境腐蚀的主要特征<sup>[9-10]</sup>，装备在南海岛礁上面临着恶劣的大气环境考验。南海岛礁主要环境特点：年平均气温为 28~30℃，高温纪录极值为 60℃，夏季炎热天气(气温大于 30℃)持续时间多达 140 d 左右；雨水充足，年降雨量 2 800 mm 以上；年平均湿度达 85%左右，全年平均相对湿度均在金属腐蚀临界湿度的 70%以上，装备的金属构件受腐蚀相对湿度临界值如表 1 所示；盐雾浓度高，空气中的盐雾含量在 0.3~1.5 g/(m<sup>2</sup>·d)，是大陆沿海地区的 1.5 倍<sup>[11]</sup>，且盐的成分复杂，如表 2—3 所示<sup>[12]</sup>。由此可见，南海岛礁的主要气候特点为高温、高湿、高盐雾和强光照，气候环境恶劣，装备将受到严酷大气腐蚀环境的挑战。

| 表 1 不同金属腐蚀的相对湿度临界值 % |        |         |
|----------------------|--------|---------|
| 金属类别                 | 普通空气湿度 | 含酸性空气湿度 |
| 铁                    | 70     | 60      |
| 锌                    | 65     | 49      |
| 铜                    | 70     | 6       |
| 铝                    | 65     | 52      |

| 表 2 沿海/内陆大气环境对比 |        |        |        |         |                             |
|-----------------|--------|--------|--------|---------|-----------------------------|
| 地点              | 环境因素   |        |        |         |                             |
|                 | 年均气温/℃ | 高低温/℃  | 平均湿度/% | 年降雨量/mm | Cl 含量/(g/m <sup>2</sup> ·d) |
| 北京              | 12.0   | 39/-17 | 57     | 552     | 0.000 5                     |
| 武汉              | 17.0   | 40/-10 | 77     | 1 234   | 0.001 1                     |
| 三亚              | 24.7   | 37/8   | 87     | 1 899   | 0.067 1                     |

| 表 3 海洋盐雾的多种成分 % |                  |                   |                   |                   |                   |                                |
|-----------------|------------------|-------------------|-------------------|-------------------|-------------------|--------------------------------|
| 成分              | H <sub>2</sub> O | NaCl <sub>2</sub> | MgCl <sub>2</sub> | MgSO <sub>4</sub> | CaSO <sub>4</sub> | K <sub>2</sub> SO <sub>4</sub> |
| 占比              | 90               | 7.78              | 1.09              | 0.47              | 0.36              | 0.25                           |
|                 |                  |                   |                   |                   |                   | 0.04                           |

2 腐蚀速率预测模型建立

2.1 主要影响因素提取

在严酷的大气腐蚀环境下，影响装备腐蚀的因素繁多，彼此间有复杂的关系，若将影响小的因素作为主要预测变量，预测模型的精度会下降<sup>[13]</sup>，因此，要对影响因素进行特征提取。KPCA 是将原始数据映射到高维空间中做数据压缩提取主要特征向量<sup>[14]</sup>，累计贡献率大于 85 的核主成分为最优选取值<sup>[15]</sup>。

对装备腐蚀原始样本数据进行预处理，对影响因素进行归一化处理，输入到 KPCA 进行特征筛选，筛选过程如下：

1) 设将标准化处理后的矩阵  $\mathbf{X}_{n \times m}$  通过非线性映射  $\Phi$  映射至高维特征空间  $R^F$ ，使用主成分分析法计算得到协方差矩阵为：

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n \Phi(z_i) \Phi(z_i)^T. \tag{1}$$

2) 引入核函数  $k(z_i, z_j) = \Phi(z_i)^T \Phi(z_j)$ ，对  $\mathbf{C}$  中数据处理后可得：

$$k\eta = \lambda\eta. \tag{2}$$

式中： $\lambda$  为特征值； $\eta$  为特征向量。

3) 由式  $y_i = \sum_{i=1}^n \eta_i^T k(z_i, z_j)$  求得降序排列  $m$  个特征值  $\lambda_m (m=1, 2, \dots, m)$  和其对应的特征向量  $\eta_m (m=1, 2, \dots, m)$ ，满足贡献率大于等于 85%。

4) 在满足 3)的条件下，降维映射后的非线性样本  $H$ ：

$$H = \left[ \sum_{i=1}^n \eta_i \Phi(z_i) \right]^T. \tag{3}$$

筛选后的数据分为训练集和测试集，将训练集用于 HDBO 迭代寻优。

## 2.2 腐蚀速率预测模型构建

### 2.2.1 KELM 腐蚀速率预测模型构建

为解决 ELM 随机生成输入权值而影响算法稳定性的问题, Huang 等<sup>[16]</sup>于 2012 年提出核极限学习机算法。本文中 KELM 算法引入高斯核函数代替 ELM 中的激励函数, 求解 KELM 的逼近函数为:

$$F(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_n) \end{bmatrix} \left( \frac{I}{C} + \Omega_{\text{ELM}} \right)^{-1} T. \quad (4)$$

式中:  $\Omega_{\text{ELM}}$  为核矩阵;  $K(c, v)$  为高斯核函数。

由式(4)可知, KELM 回归预测性能受核参数  $\sigma^2$  和正则化系数  $C$  的影响, 当参数选择不合适时会影响模型的泛化能力, 并且预测结果误差也会受到影响, 故使用改进的蜣螂优化算法对核参数  $\sigma^2$  和正则化系数  $C$  进行寻优。

模型构建过程如图 1 所示。




图 1 装备结构件腐蚀速率预测流程

### 2.2.2 HDBO 寻优 KELM 参数

蜣螂优化算法基于蜣螂“滚球、跳舞、觅食、偷窃和繁殖”等行为启发, 具有寻优能力强、收敛速度快等特点。蜣螂优化算法在文献[17]中已有详细介绍, 在此不再赘述。HDBO 具体寻优过程如下:

1) 参数设定。初始化蜣螂种群, 设置种群数量 50 只, 滚球蜣螂、产卵蜣螂、觅食蜣螂和小偷蜣螂比例为 2:4:2:2。

基本蜣螂优化算法的初始蜣螂位置是随机分布的, 位置分布不均匀使得种群多样性减少, 算法优化速度减慢。笔者采用混沌映射策略改进蜣螂种群初始化分布, 使得算法在初始化时具有更均匀的种群状态。Singer 映射作为混沌映射的典型代表, 数学形式简单, 具有遍历性和随机性, 如图 2 和 3 所示。Singer 映射公式为:

$$X_{k+1} = u(7.86x_k - 23.31x_k^2 + 28.75x_k^3 - 13.302875x_k^4). \quad (5)$$

式中  $u \in (0.9, 1.08)$ 。




图 2 随机分布初始化种群




图 3 Singer 映射初始化种群

2) 设定边界范围。使用边界选择策略模拟蜣螂产卵区域, 表达式为:

$$\begin{aligned} Lb^* &= \max \{x^* \times (1-r), Lb\} \\ Ub^* &= \min \{x^* \times (1-r), Ub\} \end{aligned} \quad (6)$$

式中:  $x^*$  为当前最优位置;  $Lb$  为下界;  $Ub$  为上界。

3) 算法迭代。更新蜣螂位置, 滚球蜣螂在搜索范围内沿着设定的方向移动, 蜣螂的位置更新为:

$$\begin{aligned} x_i(t+1) &= x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \\ \Delta x &= |x_i(t) - X^w| \end{aligned} \quad (7)$$

式中:  $t$  为当前迭代次数;  $x_i$  为第  $i$  个蜣螂的位置;  $k \in (0, 0.2]$  为定值, 表示偏转系数;  $b \in (0, 1)$  为一个随机数;  $\alpha$  取 1 或 -1;  $x^w$  为全局最差位置;  $\Delta x$  为模拟光强变化。

蜣螂产卵和蜣螂觅食的位置随着产卵区域位置而动态更新, 这导致了他们搜索方式的盲目性和单一性。受鲸鱼优化算法螺旋操作的启发, 引入了可变螺旋位置更新策略, 使得繁殖位置和觅食蜣螂觅食均以螺旋形式在空间中搜索, 扩展了蜣螂探索未知区域的能力, 有助于算法跳出局部最优, 有效提高算法的全局搜索能力。

螺旋参数  $z$  公式为:

$$z = e^{k \cdot \cos(\pi / \max t)}. \quad (8)$$

蛭螂产卵位置改进后为：

$$B_i^{t+1} = x_{\text{gbest}}' + e^{z_l} \cdot \cos(2\pi l) \cdot b_1 (B_i^t - Lb^*) + e^{z_l} \cdot \cos(2\pi l) \cdot b_2 (B_i^t - Ub^*) \quad (9)$$

式中：\$B\_i^t\$ 为在第 \$t\$ 次迭代中第 \$i\$ 个蛭螂卵位置；\$b\_1\$ 和 \$b\_2\$ 为 \$1 \times D\$ 的 2 个独立随机变量；\$D\$ 为维数。

觅食蛭螂觅食位置改进后为：

$$x_i^{t+1} = e^{z_l} \cdot \cos(2\pi l) x_i^t + C_1 \cdot (x_i^t - Lb^l) + C_2 \cdot (x_i^t - Ub^l) \quad (10)$$

式中：\$x\_i^t\$ 为第 \$t\$ 次迭代中第 \$i\$ 个小蛭螂位置；\$C\_1\$ 为服从正态分布随机数；\$C\_2 \in (0, 1)\$ 为随机向量。

当面对高维复杂问题时，蛭螂算法仍然存在陷入局部最优的可能性；因此，引入 Levy 飞行策略来提高算法解的随机性，Levy 飞行是一种基于莱维分布的随机搜索，用于产生随机步长，为解增加一个扰动量，丰富种群多样性，提高算法的搜索能力，使算法跳出局部最优。且引入自适应权重，可以很好地平衡搜索多样性与收敛准确性之间的关系。基于蛭螂的特性，自适应权重的公式如下：

$$w = \frac{e^{2 \times (1-t/\max t)} - e^{-2 \times (1-t/\max t)}}{e^{2 \times (1-t/\max t)} + e^{-2 \times (1-t/\max t)}} \quad (11)$$

加入 Levy 飞行策略的小偷蛭螂位置更新公式：

$$x_i^{t+1} = \text{levy} \cdot x_{\text{best}}' + S \cdot g \cdot (|x_i^t - x_{\text{gbest}}'| + |x_i^t - w \cdot x_{\text{best}}'|) \quad (12)$$

式中：\$x\_i^t\$ 为第 \$t\$ 次迭代中第 \$i\$ 个偷蛭螂的位置；\$g\$ 为 \$1 \times D\$ 的服从正态分布的随机变量；\$S\$ 为常量。

4) 设定终止迭代条件。最大迭代次数 30 次，设定偏转系数 \$k\$ 取 0.1，\$b\$ 取 0.3，\$\delta\$ 取 \$\pi/3\$，动态更新蛭螂位置信息并判断目标是否超出边界。更新当前最优解及适应度值，当算法达到最大迭代次数后终止，输出最优解。最后将测试集输入训练好的 HDBO-KELM 模型，验证模型的预测效果。

### 2.3 模型验证指标

选取均方误差 (MSE) 和平均绝对误差值 (MAE) 对 KPCA-HDBO-KELM 模型预测效果进行评价分析：

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \quad (14)$$

式中：\$n\$ 为数据样本总量；\$\hat{y}\_i\$ 为样本预测值；\$y\_i\$ 为样本真实值。一般认为，平均绝对误差较平均误差更能反应预测值误差的实际情况，均方误差则可反

应预测的稳定性。

## 3 实例分析

### 3.1 数据准备

笔者研究数据来源于中国腐蚀与防护网公布的黑色金属大气腐蚀速率数据库，选取温度、相对湿度、光照时间、含盐量、降水量、PH 值作为特征变量；数据样本标签变量为金属腐蚀速率，如表 4 所示。

表 4 腐蚀速率及影响因素数据

| 序号<br>i | 温度<br>T/°C | 湿度<br>H/% | 降水量<br>P/mm | 光照<br>时间<br>t/h | 含盐量<br>TDS/mg | PH  | 腐蚀速率<br>v/(mm/a) |
|---------|------------|-----------|-------------|-----------------|---------------|-----|------------------|
| 1       | 29         | 83        | 101         | 5.0             | 135           | 6.2 | 2.12             |
| 2       | 37         | 98        | 103         | 5.3             | 144           | 5.9 | 1.84             |
| 3       | 38         | 88        | 88          | 4.6             | 158           | 6.2 | 4.36             |
| 4       | 41         | 83        | 134         | 5.2             | 136           | 6.3 | 1.19             |
| 5       | 28         | 90        | 125         | 4.6             | 126           | 6.1 | 2.31             |
| 6       | 37         | 86        | 97          | 6.4             | 143           | 6.2 | 3.13             |
| 7       | 35         | 83        | 88          | 5.4             | 136           | 6.4 | 2.64             |
| 8       | 40         | 86        | 102         | 6.6             | 139           | 5.6 | 3.22             |
| 9       | 31         | 89        | 112         | 5.3             | 141           | 5.8 | 1.45             |
| 10      | 35         | 90        | 98          | 6.8             | 129           | 6   | 4.31             |
| ⋮       | ⋮          | ⋮         | ⋮           | ⋮               | ⋮             | ⋮   | ⋮                |
| 57      | 40         | 83        | 89          | 5.2             | 139           | 5.8 | 2.24             |
| 58      | 36         | 90        | 111         | 6.4             | 131           | 5.8 | 1.51             |
| 59      | 31         | 85        | 94          | 5.3             | 141           | 6.3 | 3.43             |
| 60      | 35         | 89        | 102         | 6.7             | 137           | 6.7 | 3.52             |

### 3.2 数据预处理

为消除不同腐蚀因素之间的量纲对预测模型输出结果的影响，对数据进行归一化处理，并用 KPCA 数据降维，进行非线性特征提取，结果如图 4 所示。




图 4 KPCA 累计贡献率

由图 4 可以看出：温度、湿度和降水量累计贡献率达到 95.63%，故将次 3 项特征作为腐蚀速率预测的主要指标。

### 3.3 模型训练与结果分析

将 KPCA 降维重构后的 60 组样本数据集随机划分排序，选取前 50 组数据集作为训练样本数据，剩余 10 组数据作为测试集数据。模型参数按照 2.2 节进行设置，为验证 KPCA-HDBO-KELM 模型性能，将其与多个预测模型进行对比，结果如图 5 所示。




图 5 不同模型下测试样本的预测结果对比

由图 5 可知: KPCA-HDBO-KELM 预测结果较其他模型更接近真实数据集, 且预测稳定性更好。

采用 3.2 节列出的模型验证指标对 KPCA-HDBO-KELM 模型性能进一步评价验证, 结果如图 6 所示。




图 6 不同模型下统计学指标对比

由图 6 可看出: KPCA-HDBO-KELM 模型相较于其他 2 个模型 MSE 和 MAE 指标值最低, 分别为 0.827 和 1.001。以上分析可以证明: KPCA-HDBO-KELM 模型预测性能优于其他比较模型, 可用于装备结构件腐蚀速率的预测。

## 4 结论

1) 影响装备腐蚀速率的大气因素较多, 各因素相互叠织影响了模型预测精度, 采用 KPCA 提取影响装备腐蚀的关键指标, 分析出温度、湿度和降水量是影响装备腐蚀的主要因素, 降低了 KELM 的输入指标维度, 避免出现“维数灾难”。

2) KELM 模型核参数和正则化系数的设定会影响预测精度, 采用 HDBO 算法对核参数和正则化系数进行寻优。构建的 KPCA-HDBO-KELM 模型预测结果较其他 2 种模型更接近真实值, 且统计学指标均方误差和平均绝对误差均较小, 优于其他比较模型, 表明该模型具有更好的精度和鲁棒性。

## 参考文献:

[1] MORALES J, MARTIN K S, DIAZ F, et al. Atmospheric

Corrosion in Subtropical Areas: Influences of Time of Wetness and Deficiency of the ISO 9223 Norm[J]. Corrosion Science, 2005, 47(8): 2005-2019.

[2] MENDOZA A R, CORVO F. Outdoor and Indoor Atmospheric Corrosion of Non-Ferrous Metals[J]. Corrosion Science, 2000, 42(7): 1123-1147.

[3] 向永华, 王争荣, 曹京宜, 等. 岛礁装备设施腐蚀现状及腐蚀控制策略研究[J]. 装备环境工程, 2021, 18(11): 28-34.

[4] 柏淘雨, 余华云, 宋文广. 改进 MGM (1, 1) 的管道腐蚀速率预测模型构建[J]. 机械设计与制造工程, 2022, 52(4): 69-73.

[5] 张新生, 赵梦旭, 王小完, 等. 尾段残差修正 GM(1, 1) 模型在管道腐蚀预测中的应用[J]. 中国安全科学学报, 2017, 27(1): 65-70.

[6] 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.

[7] 王盼锋, 王寿喜, 马钢, 等. 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.

[8] 骆正山, 李蕾, 王小完. 基于 LASSO-MBAS-ELM 的海底多相流管道 CO<sub>2</sub> 内腐蚀速率预测[J]. 热加工工艺, 2023, 52(14): 41-45.

[9] 陈群志, 鞠明, 余文波, 等. 严酷环境下飞机外场腐蚀防护对策与措施[J]. 装备环境工程, 2017, 14(3): 1-7.

[10] 于峰, 张福生, 孟宪会. 海洋环境下载人航天器电子设备防护技术[J]. 航天器环境工程, 2017, 34(3): 330-335.

[11] 肖军, 廖志忠, 吴连锋. 空空导弹弹体结构海洋环境腐蚀防护[J]. 航空兵器, 2019, 26(6): 86-92.

[12] MANSFELD F. Atmospheric corrosion rates, time-of-wetness and relative humidity[J]. Materials & Corrosion, 1979, 30(1): 38-42.

[13] PEI Y C, FAN Y G, LIAO Y, et al. Wearing fault diagnosis application of reciprocating membrane pump based on KPCA[J]. Advanced Materials Research, 2014, 3255: 864-865.

[14] 肖鹏, 谢行俊, 双海清. 基于 KPCA-GMGANN 算法的瓦斯涌出量预测研究[J]. 中国安全科学学报, 2020, 30(5): 39-47.

[15] 骆正山, 姚梦月, 骆济豪, 等. 基于 KPCA-BAS-GRNN 的埋地管道外腐蚀速率预测[J]. 表面技术, 2018, 47(11): 173-180.

[16] HUANG G B, WANG D H, LAN Y. Extreme Learning Machines: A Survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107-122.

[17] XUE J, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.