



DOI:10.12404/j.issn.1671-1815.2408240

引用格式:王宏,储盼,管大松,等.基于 IDBO-HKELM 的冷水机组故障诊断方法[J].科学技术与工程,2025,25(22):9505-9513.

Wang Hong, Chu Pan, Guan Dasong, et al. Chiller fault diagnosis method based on IDBO-HKELM[J]. Science Technology and Engineering, 2025, 25(22): 9505-9513.

基于 IDBO-HKELM 的冷水机组故障诊断方法

王宏^{1,2}, 储盼^{1,2}, 管大松^{3*}, 郭洋^{1,2}, 田增瑞^{1,2}, 盛英杰^{1,2}

(1. 郑州轻工业大学建筑环境工程学院, 郑州 450000; 2. 河南省智慧建筑与人居环境工程技术研究中心, 郑州 450000;
3. 中国建筑技术集团有限公司, 北京 100013)

摘要 冷水机组作为建筑中的关键设备和主要能耗源,若其发生故障不仅会影响系统的正常运行,还会造成严重的能源浪费。为提升冷水机组系统运行的可靠性,构建了一种多策略改进蜣螂优化算法(improve dung beetle optimizer, IDBO)和混合核极限学习机(hybrid kernel extreme learning machine, HKELM)融合的故障诊断模型,用于实现冷水机组早期故障的精确诊断。该模型首先采用混合核函数提高核极限学习机(kernel extreme learning machine, KELM)的学习能力和泛化性,其次将 Bernoulli 映射、自适应惯性因子和 Levy 飞行融合动态权重系数策略用于改进蜣螂优化算法(dung beetle optimizer, DBO),以平衡 DBO 算法的全局探索性能。最后通过基准函数验证 IDBO 算法的有效性,利用 IDBO 算法对 HKELM 超参数进行优化,从而构建用于冷水机组早期故障诊断的数据驱动模型。通过相关训练仿真和实验验证,所提出的 IDBO-HKELM 模型对冷水机组的早期故障诊断准确率提高到 99.71%,对比其他算法具有明显优势。

关键词 冷水机组; 群体算法; HKELM; IDBO 算法; 故障诊断

中图分类号 TU831.6 TP277; **文献标志码** A

Chiller Fault Diagnosis Method Based on IDBO-HKELM

WANG Hong^{1,2}, CHU Pan^{1,2}, GUAN Da-song^{3*}, GUO Yang^{1,2}, TIAN Zeng-rui^{1,2}, SHENG Ying-jie^{1,2}

(1. College of Building Environment Engineering, Zhengzhou University of Light Industry, Zhengzhou 450000, China;
2. Henan Engineering Research Center of Intelligent Buildings and Human Settlements, Zhengzhou 450000, China;
3. China Construction Technology Group Ltd., Beijing 100013, China)

[Abstract] As a key equipment and a major source of energy consumption in a building, chiller plant, if it fails, it will not only affect the normal operation of the system, but also cause serious energy waste. In order to improve the reliability of chiller system operation. A multi-strategy IDBO (improved dung beetle optimization algorithm) combined with a HKELM (hybrid kernel extreme learning machine) fusion fault diagnosis model was constructed to achieve accurate diagnosis of early faults in chiller systems. The model firstly employs hybrid kernel functions to improve the learning ability and generalization of KELM (kernel-extreme learning machine). Secondly, Bernoulli mapping, adaptive inertia factor, and Levy flight fusion dynamic weight coefficients strategies were used to improve the DBO (dung beetle optimization) algorithm in order to balance the global exploration performance of the DBO algorithm. Finally, the effectiveness of the IDBO algorithm was verified by benchmark functions, and the HKELM hyperparameters are optimized using the IDBO algorithm to construct a data-driven model for early fault diagnosis of chiller units. Through relevant training simulations and experimental validation, the accuracy of the proposed IDBO-HKELM model for early fault diagnosis of chillers is improved to 99.71%, which is an obvious advantage over other algorithms.

[Keywords] chiller; swarm algorithm; HKELM (hybrid kernel extreme learning machine); fault diagnosis; IDBO (improved dung beetle optimization) algorithm

当前,在中国“3060”双碳目标背景下,节能减排与可持续发展是中国建筑行业所面临的巨大挑战,有效降低建筑能耗和提高能源利用率已成为中

国建筑行业转型发展的新态势。据统计,空调系统的能源消耗占据建筑总能耗的 40%~50%^[1],而冷水机组作为空调系统的核心设备,性能下降和出现

收稿日期:2024-11-05; 修订日期:2025-05-15

基金项目:河南省科技攻关项目(232102211050,252102241002);郑州轻工业大学产业技术研究院 2024 年度概念验证项目(YJYGNZY-2024005);郑州轻工业大学博士研究生基金资助项目(13501050025)

第一作者:王宏(1977—),男,汉族,河南平顶山人,硕士,教授。研究方向:智能建筑设备节能优化控制、故障诊断及智慧运维。E-mail: wanghong@zzuli.edu.cn.

*通信作者:管大松(1969—),男,汉族,北京人,教授级高级工程师。研究方向:建筑设备节能、智能化控制。E-mail:C960850C@163.com.

故障会导致大量的能源浪费。因此,提升冷水机组的故障分类性能,保证冷水机组高效、安全、稳定的工作是提高能源利用率的有效途径。

基于数据驱动的故障诊断方法已经成为一个重要的研究方向^[2],为提升故障检测效率和准确性提供了新途径。支持向量机^[3-4]和人工神经网络^[5-7]等方法已用于建立冷水机组的故障诊断模型,但支持向量机难以训练大规模的样本。相比之下,虽然人工神经网络具备大规模样本学习的能力,但其训练速度较慢。极限学习机(extreme learning machine, ELM)是一种单隐藏层前向神经网络,具有简单、快速学习的特点^[8],然而,ELM的输入权重和阈值的隐藏层是随机确定的,这使得建立正确数量的隐藏层具有挑战性^[9]。核极限学习机(kernel extreme learning machine, KELM)使用核映射而不是随机映射,降低了网络的复杂度,显著提高了模型的预测和泛化能力^[10],但是,KELM通常在应用过程中使用单个核函数,难以适应具有各种数据属性的样本。近年来,通过对不同的核函数进行加权,学者们提出了混合核极限学习机(hybrid kernel extreme learning machine, HKELM),该混合核极限学习机可以解决KELM中的单个核函数难以检索多维样本的问题^[11-12]。然而,混合核极限学习机的泛化能力与分类能力却受到核函数类型与超参数的强烈影响。蛭螂优化算法(dung beetle optimizer, DBO)可用于优化混合核极限学习机的超参数,其具有结构简单,调节参数少,操作简单,全局优化能力强等特点。但DBO在寻优过程中,仍存在收敛速度较慢,容易陷入局部最优等问题^[13]。

针对上述问题,现提出一种多策略改进蛭螂优化算法(improved dung beetle optimizer, IDBO)和HKELM融合的冷水机组故障诊断方法。首先,将Bernoulli映射、自适应惯性因子和Levy飞行融合动态权重系数策略引入DBO,提出IDBO算法,通过多个基准函数测试,证明IDBO具有良好的收敛性与稳定性。其次,选择多种核函数组成的HKELM模型,并使用IDBO对HKELM超参数寻优,解决HKELM参数较多且性能受参数影响较大的问题。最后采用ASHRAE 1043-RP的数据集进行对比实验,验证所提出故障诊断模型的优越性。

1 解析 HKELM 模型

1.1 KELM 模型

ELM虽然具有训练速度快、克服了传统梯度算法的局部极小等优点,但在较复杂的分类、回归等非线性模式识别任务往往需要更多的隐层神经元,导致网络的结构非常复杂^[14]。针对ELM的不足,

研究者们提出了一种核极限学习机^[15]。该方法不需要显式地定义映射函数,也不需要设置隐层神经元个数,从而节省了隐层神经元个数优化的时间。核矩阵定义为

$$\Omega_{\text{KELM}}(\mathbf{X}) = h(\mathbf{X})\mathbf{H}^T \quad (1)$$

式(1)中: $h(\mathbf{X})$ 为隐藏层的输入到输出的映射; \mathbf{X} 为输入数据矩阵; \mathbf{H} 为隐藏层输出矩阵。

矩阵中第*i*行和第*j*列的元素表示为

$$\Omega_{\text{KELM}_{ij}}(\mathbf{x}_i, \mathbf{x}_j) = h(\mathbf{x}_i)h(\mathbf{x}_j) \triangleq K(\mathbf{x}_i, \mathbf{x}_j) \quad (2)$$

式(2)中: $\Omega_{\text{KELM}_{ij}}(\mathbf{x}_i, \mathbf{x}_j)$ 表示核矩阵中的元素,衡量输入样本 \mathbf{x}_i 和 \mathbf{x}_j 间的相似性; $h(\mathbf{x}_i)$ 和 $h(\mathbf{x}_j)$ 分别为输入数据 \mathbf{x}_i 和 \mathbf{x}_j 映射到高维空间的表示; \triangleq 表示等价; $K(\mathbf{x}_i, \mathbf{x}_j)$ 为数据 \mathbf{x}_i 和 \mathbf{x}_j 在高维特征空间的内积。

$$\mathbf{f}_{\text{KELM}}(\mathbf{X}) = [\mathbf{K}(\mathbf{X}\mathbf{x}_1) \cdots \mathbf{K}(\mathbf{X}\mathbf{x}_N)] \times [\Omega_{\text{KELM}}(\mathbf{X})]^{-1}\mathbf{Y} \quad (3)$$

式(3)中: $\mathbf{f}_{\text{KELM}}(\mathbf{X})$ 为模型KELM的输出; $\mathbf{K}(\mathbf{X}\mathbf{x}_1)$ 和 $\mathbf{K}(\mathbf{X}\mathbf{x}_N)$ 为输入数据 \mathbf{X} 和样本 $\mathbf{x}_1, \mathbf{x}_N$ 在特征空间的相似性; \mathbf{Y} 为目标输出矩阵。

引入正则化后,公式为

$$\mathbf{f}_{\text{KELM}}(\mathbf{X}) = [\mathbf{K}(\mathbf{X}\mathbf{x}_1) \cdots \mathbf{K}(\mathbf{X}\mathbf{x}_N)] \times \left[\frac{\mathbf{I}}{C} + \Omega_{\text{KELM}}(\mathbf{X}) \right]^{-1}\mathbf{Y} \quad (4)$$

KELM的网络输出 $\mathbf{f}_{\text{KELM}}(\mathbf{X}_k)$ 可写为

$$\mathbf{f}_{\text{KELM}}(\mathbf{X}_k) = \sum_{k=1}^n \Omega_{\text{KELM}}(\mathbf{X}\mathbf{x}_k) \left[\left(\frac{\mathbf{I}}{C} \right)_k + \Omega_{\text{KELM}}(\mathbf{X}\mathbf{x}_k) \right]^{-1} \mathbf{Y}_k \quad (5)$$

式(5)中: $\mathbf{f}_{\text{KELM}}(\mathbf{X}_k)$ 为KELM模型对输入数据 \mathbf{X} 中第*k*个样本的函数输出; $\Omega_{\text{KELM}}(\mathbf{X}\mathbf{x}_k)$ 为核矩阵; C 为正则化系数; \mathbf{I} 为单位矩阵。

KELM通过使用核函数将低维空间转化为高维空间,大大降低了网络的复杂性,提高了预测和泛化能力。然而,典型的KELM算法的单核函数难以处理各种样本数据,由此采用了混合核极限学习机的方法。通过引入混合核函数,可以弥补单核ELM的缺陷,解决泛化能力差和预测精度低等问题。

1.2 HKELM 模型

核函数的类型很多,综合常见核函数的特性,权衡模型精度与计算复杂度。本文采用将多项式函数(polynomial function, Poly)和径向基函数(radial basis function, Rbf)进行加权组合的混合核极限学习机,并构造其两种组合的等效核函数。使模型可以兼具Poly核函数与Rbf核函数的优点,进一步提高KELM的学习能力和泛化性能^[16]。相较于其他核函数得到更好的泛化性能,其输出模型为

$$\mathbf{f}(\mathbf{x}) = h(\mathbf{x})\boldsymbol{\beta} = \mathbf{H}\boldsymbol{\beta} \quad (6)$$

式(6)中: \mathbf{x} 为样本数据; $f(\mathbf{x})$ 为输出; $h(\mathbf{x})$ 为隐含层输入; \mathbf{H} 为特征映射矩阵; $\boldsymbol{\beta}$ 为输出权重矩阵。

$$\boldsymbol{\beta} = \mathbf{H}^T \left(\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{A} \quad (7)$$

式(7)中: \mathbf{A} 为训练集目标矩阵。

KELM核函数定义为

$$\begin{cases} \boldsymbol{\Omega} = \mathbf{H}\mathbf{H}^T \\ \Omega_{i,j} = h(\mathbf{x}_i)h(\mathbf{x}_j) = \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) \end{cases} \quad (8)$$

式(8)中: $\boldsymbol{\Omega}$ 表示矩阵; $\Omega_{i,j}$ 为核矩阵中的第*i*行和第*j*列的元素。

因此可得出输出模型为

$$\begin{aligned} f(\mathbf{x}) &= \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ K(\mathbf{x}, \mathbf{x}_2) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_N) \end{bmatrix} \mathbf{A} \left(\frac{\mathbf{I}}{C} + \boldsymbol{\Omega} \right)^{-1} \mathbf{A} \\ &= \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ K(\mathbf{x}, \mathbf{x}_2) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_N) \end{bmatrix} \mathbf{A}\boldsymbol{\beta} \end{aligned} \quad (9)$$

采用的混合核函数可以表示为

$$K_{\text{mix}}(\mathbf{x}, \mathbf{x}_j) = rK_{\text{poly}}(\mathbf{x}, \mathbf{x}_j) + (1-r)K_{\text{rbf}}(\mathbf{x}, \mathbf{x}_j), \quad r \in [0, 1] \quad (10)$$

式(10)中: K_{poly} 和 K_{rbf} 分别为Poly和Rbf的核函数; r 为线性平衡因子。

$$K_{\text{poly}}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}, \mathbf{x}_i + c_1)^d \quad (11)$$

$$K_{\text{rbf}}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}\right) \quad (12)$$

式中: σ 、 c_1 、 d 为Poly核函数与Rbf核函数的核参数。

由此可见, HKELM需求参数较多,故需要对模型中的参数进行寻优,提升分类性能。

2 混合多策略改进 DBO 算法

Xue等^[17]受到自然界中蜣螂的生存行为启发,提出了DBO算法。该算法模拟了蜣螂的滚球、跳舞、觅食、偷窃和繁殖行为。

在滚动过程中,滚球蜣螂依靠天气线索进行导航,以确保粪球沿直线方向滚动。蜣螂在滚动时位置变化的表示为

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \alpha k \mathbf{x}_i(t-1) + b\Delta\mathbf{x} \quad (13)$$

$$\Delta\mathbf{x} = |\mathbf{x}_i(t) - \mathbf{X}^w| \quad (14)$$

式中: $\mathbf{x}_i(t)$ 为迭代所对应第*i*只蜣螂的位置信息; α 为是否偏离原来位置; k 为偏转系数; \mathbf{X}^w 为整体的最差位置; $\Delta\mathbf{x}$ 为模拟自然光的强弱。

蜣螂产卵时的迭代位置更新公式为

$$\mathbf{B}_i(t+1) = \mathbf{X}^* + b_1[\mathbf{B}_i(t) - \mathbf{L}_b^*] + b_2[\mathbf{B}_i(t) - \mathbf{U}_b^*] \quad (15)$$

式(15)中: \mathbf{X}^* 为局部最佳位置; $\mathbf{B}_i(t)$ 为第*t*次迭代时第*i*个卵球的位置; \mathbf{L}_b^* 和 \mathbf{U}_b^* 为产卵区域的下界和上界; b_1 和 b_2 为两个独立大小为 $1 \times d$ 的随机量; d 为解决问题的维数。

DBO在寻优过程中,仍存在收敛速度较慢,容易陷入局部最优等问题。因此,为提升该算法的精度和收敛性能,提出了一种多策略改进蜣螂优化算法,从而对HKELM模型中的参数进行寻优,提升其分类性能。

2.1 Bernoulli 映射初始化种群

Bernoulli映射是一种混沌系统,其轨迹对初始条件极为敏感,微小的初始变化会迅速导致不同的结果^[18]。因此本文研究中采用Bernoulli混沌映射,通过遵循特定的规律来遍历搜索空间,避免了初始化种群分布不均匀的问题。Bernoulli映射模型为

$$Z_{t+1} = \begin{cases} \frac{Z_t}{1-\lambda}, & Z_t \in (0, 1-\lambda) \\ \frac{Z_t - 1 + \lambda}{\lambda}, & Z_t \in (0, 1-\lambda) \end{cases} \quad (16)$$

$$X_{td} = X_L + (X_U - X_L)Z_{td} \quad (17)$$

式中: Z_t 为产生的第*t*代混沌序列的当前值; Z_{t+1} 为在第*t+1*代时所产生的混沌值; λ 为调节系数; X_{td} 为第*t*个元素在*d*维的位置; X_U 、 X_L 为搜索空间的上、下限; Z_{td} 为第*t*个元素在*d*维上产生的混沌值。

2.2 自适应惯性因子

钻出地面寻找食物的为小蜣螂。其最佳觅食区的边界定义为

$$\mathbf{L}_b^b = \max[\mathbf{X}^b(1-R), \mathbf{L}_b] \quad (18)$$

$$\mathbf{U}_b^b = \min[\mathbf{X}^b(1-R), \mathbf{U}_b]$$

式(18)中: \mathbf{X}^b 为最优位置; \mathbf{L}_b^b 和 \mathbf{U}_b^b 分别为最佳寻找食物范围的下限和上限; \mathbf{L}_b 和 \mathbf{U}_b 分别为寻找空间下限和上限; $R = 1 - (t/T_{\text{max}})$; t 为当前迭代次数; T_{max} 为最大迭代次数。

位置更新为

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + C_1[\mathbf{x}_i(t) - \mathbf{L}_b^b] + C_2[\mathbf{x}_i(t) - \mathbf{U}_b^b] \quad (19)$$

但觅食小蜣螂在面对位置更新陷入局部最优时,会使得种群不再进行遍历搜索。为了解决这一问题,本文在此阶段引入了自适应因子*m*和*n*,算法表达式为

$$\begin{cases} m = 2r_{\text{and}} - 1 \\ n = \exp\left\{5\cos\left[\pi\left(\frac{1-t}{T_{\text{max}}}\right)\right]\right\} \end{cases} \quad (20)$$

$$\mathbf{x}_i(t+1) = \exp(mn)\cos(2\pi n)\mathbf{x}_i(t) + C_1[\mathbf{x}_i(t) - \mathbf{L}_b^b] + C_2[\mathbf{x}_i(t) - \mathbf{U}_b^b] \quad (21)$$

式中: r_{and} 为 0 ~ 1 的随机数; C_1 为服从正态分布的随机数; C_2 为 0 ~ 1 范围内的随机向量。

2.3 莱维飞行策略融合动态权重系数

若所有蛭螂个体都集中在当前最优解附近, 随着迭代的继续, 算法会陷入停滞, 此时得到的解并非全局最优。为了克服算法易陷入局部最优的问题, 本文研究将莱维 (Levy) 飞行引入到偷窃蛭螂的位置信息更新过程中^[19], 在加强局部邻域搜索的同时, 也可探测到算法空间中的较远解。

Levy 飞行的公式为

$$L = \frac{\tau u}{(|v|^{1/\beta})} \quad (22)$$

$$u \sim N(0, \sigma^2), v \sim N(0, 1) \quad (23)$$

$$\sigma = \left[\frac{\Gamma(1 + \beta) \sin \frac{\pi\beta}{2}}{\Gamma\left(\frac{1 + \beta}{2}\right) \beta (2^{\beta-1})} \right]^{1/\beta} \quad (24)$$

式中: u 和 v 为服从正太分布的随机数; τ 为 (0, 1) 中随机值; β 为设置为 (0, 2) 的随机值; Γ 为伽马函数。

为解决在迭代时陷入局部最优这一问题, 引入动态权重系数。

$$\omega = \frac{\mu - \mu^{-1}}{\mu + \mu^{-1}} \quad (25)$$

$$\mu = \exp\left[2\left(1 - \frac{t}{T_{\max}}\right)\right] \quad (26)$$

更新后的迭代公式为

$$x_i(t+1) = Lx^b + Sg\omega[|x_i(t) - X^*| + x_i(t) - X^b] \quad (27)$$

式中: S 为常数值; g 为随机向量; X^b 为最佳位置。

2.4 基于 IDBO-HKELM 的冷水机组故障诊断模型

IDBO-HKELM 模型的故障诊断流程图如图 1 所示, 具体步骤如下。

步骤 1 获取并划分故障数据。

步骤 2 设定种群规模、最大迭代次数。

步骤 3 通过式(17)初始化种群。

步骤 4 计算种群中个体适应度值。

步骤 5 根据式(13)、式(15)、式(19)、式(21)和式(27)更新滚球行为、繁殖行为、觅食行为和偷窃行为的个体位置, 获得更新后的种群, 并计算新位置的适应度值, 若前者更优则保持原个体位置不变, 若当前更优则更新为当前个体。

步骤 6 判断是否满足最大迭代数, 若满足则输入到最优 HKELM 模型, 若不满足则返回步骤 4。

步骤 7 将获得最优值的参数输入 HKELM 模型中。

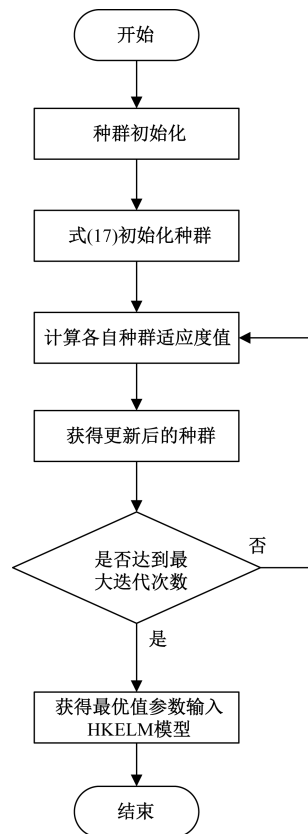


图 1 IDBO-HKELM 模型诊断流程图

Fig. 1 Diagnostic flowchart of the IDBO-HKELM model

步骤 8 输出最终结果并结束。

3 仿真研究与结果分析

3.1 IDBO 算法性能分析

为验证本文所提出 IDBO 算法改进的有效性, 采用基准测试函数进行实验, 并将麻雀搜索算法 (sparrow search algorithm, SSA)、灰狼优化算法 (grey wolf optimizer, GWO) 与原始蛭螂优化算法作为对照组。表 1 为本文选择的基准测试函数, 其中 $F_1 \sim F_3$ 为单峰测试函数、 $F_8 \sim F_{10}$ 为多峰测试函数、 F_{15} 和 F_{20} 为复合测试函数。

每个算法种群规模设置为 30, 迭代次数为 500, 独立运行 30 次, 分别求其最优值、平均值和标准差。最优值用于评价算法寻优能力, 平均值用于评价算法收敛精度, 标准差用于评价算法寻优的稳定性。具体测试结果如表 2 所示。

算法的平均适应度收敛曲线如图 2 所示, IDBO 算法在收敛精度和速度上明显优于其他 3 种对照组。特别是在单峰测试函数 $F_1 \sim F_3$ 、多峰函数 F_8 、 F_{10} 以及复合函数 F_{15} 、 F_{20} 中, IDBO 都展示出最高的收敛速度和最佳的稳定性。对于多峰基准函数 F_8 来说, 在收敛速度相同的情况下, IDBO 算法在收敛精度上也优于其他 3 种对照组。此外, 由图 2 收敛

表 1 基准测试函数表
Table 1 Benchmark functions

函数	搜索范围	理论值	参数含义
$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100,100]$	0	$-100 \leq x_i \leq 100$
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10,10]$	0	$-10 \leq x_i \leq 10$
$F_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^j x_i \right)^2$	$[-100,100]$	0	$-100 \leq x_i \leq 100$
$F_8(x) = \sum_{i=1}^n -x_i \sin \sqrt{ x_i }$	$[-500,500]$	$-418.98 \times \dim$	$-500 \leq x_i \leq 500$; dim 为维度
$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12,5.12]$	0	$-5.12 \leq x_i \leq 5.12$
$F_{10}(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right] + 20 + e$	$[-32,32]$	0	$-32 \leq x_i \leq 32$
$F_{15}(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_1 x_2)}{b_i^2 + b_1 x_3 + x_4} \right]^2$	$[-5,5]$	0.148 4	$-5 \leq x_i \leq 5$; a_i 为权重参数; b_i 为影响分子和分母的线性组合
$F_{20}(x) = \sum_{i=1}^4 c_i \exp \left[- \sum_{j=1}^6 a_{ij} (x_j - p_{ij})^2 \right]$	$[0,1]$	-3.32	$0 \leq x_i \leq 1$; c_i 为权重; a_{ij} 为惩罚系数; p_{ij} 为位置参数

表 2 基准测试函数优化结果
Table 2 Optimization results of benchmark test functions

函数名	指标	GWO	SSA	DBO	IDBO
F_1	最优值	$1.470 4 \times 10^{-29}$	$1.337 6 \times 10^{-231}$	$7.779 1 \times 10^{-167}$	0
	平均值	$1.125 9 \times 10^{-27}$	$1.454 5 \times 10^{-55}$	$3.837 9 \times 10^{-105}$	0
	标准差	$1.804 2 \times 10^{-27}$	$7.965 5 \times 10^{-55}$	$2.059 8 \times 10^{-104}$	0
F_2	最优值	$3.137 9 \times 10^{-30}$	0	$6.389 3 \times 10^{-171}$	0
	平均值	$1.050 6 \times 10^{-28}$	$6.044 3 \times 10^{-59}$	$1.150 4 \times 10^{-119}$	0
	标准差	$1.668 2 \times 10^{-28}$	$3.308 6 \times 10^{-58}$	$6.301 1 \times 10^{-119}$	0
F_3	最优值	$9.592 2 \times 10^{-18}$	$1.068 7 \times 10^{-133}$	$1.425 0 \times 10^{-84}$	0
	平均值	$1.230 2 \times 10^{-16}$	$2.051 5 \times 10^{-31}$	$2.163 9 \times 10^{-59}$	0
	标准差	$1.125 1 \times 10^{-16}$	$7.940 1 \times 10^{-31}$	$8.937 8 \times 10^{-59}$	0
F_8	最优值	$7.939 9 \times 10^{-55}$	0	$1.318 5 \times 10^{-304}$	0
	平均值	$2.618 1 \times 10^{-51}$	$5.529 2 \times 10^{-119}$	$8.333 6 \times 10^{-197}$	0
	标准差	$7.493 2 \times 10^{-51}$	$2.520 1 \times 10^{-118}$	0	0
F_9	最优值	$5.861 6 \times 10^{-4}$	$1.105 2 \times 10^{-4}$	$1.418 4 \times 10^{-4}$	$3.112 4 \times 10^{-5}$
	平均值	$2.314 7 \times 10^{-3}$	$1.634 4 \times 10^{-3}$	$1.015 2 \times 10^{-3}$	$7.385 8 \times 10^{-4}$
	标准差	$1.113 9 \times 10^{-3}$	$9.791 8 \times 10^{-4}$	$7.676 2 \times 10^{-4}$	$5.360 9 \times 10^{-4}$
F_{10}	最优值	5.010×10^{-107}	$1.118 7 \times 10^{-209}$	$1.766 7 \times 10^{-187}$	0
	平均值	1.512×10^{-96}	$7.576 3 \times 10^{-49}$	$1.306 5 \times 10^{-119}$	0
	标准差	8.132×10^{-96}	$2.885 8 \times 10^{-48}$	$7.156 0 \times 10^{-119}$	0
F_{15}	最优值	$1.393 8 \times 10^{-16}$	$2.308 7 \times 10^{-110}$	$1.485 6 \times 10^{-77}$	0
	平均值	$4.111 5 \times 10^{-4}$	$2.559 8 \times 10^{-9}$	$2.519 6 \times 10^{-1}$	0
	标准差	$5.437 1 \times 10^{-4}$	$7.428 5 \times 10^{-9}$	1.377 8	0
F_{20}	最优值	$9.298 2 \times 10^{-26}$	0	$1.286 5 \times 10^{-159}$	0
	平均值	$3.318 8 \times 10^{-24}$	$2.842 1 \times 10^{-24}$	$2.284 0 \times 10^{-99}$	0
	标准差	$1.039 5 \times 10^{-23}$	$1.425 3 \times 10^{-23}$	$1.194 1 \times 10^{-98}$	0

曲线可看出, IDBO 算法避免了种群分布不均匀的问题, 证明了在初始化阶段引入 Bernoulli 混沌映射的有效性; 同时也可看出 IDBO 算法展现出最快的收敛速度和精度, 证明了在觅食阶段引入自适应因

子以及在偷窃阶段引入莱维飞行融合动态权重系数策略的有效性, 使得算法跳出局部最优, 增强了蜣螂快速探索的能力。由此说明, IDBO 算法具有优越的全局探索能力和跳出局部最优的开发能力。

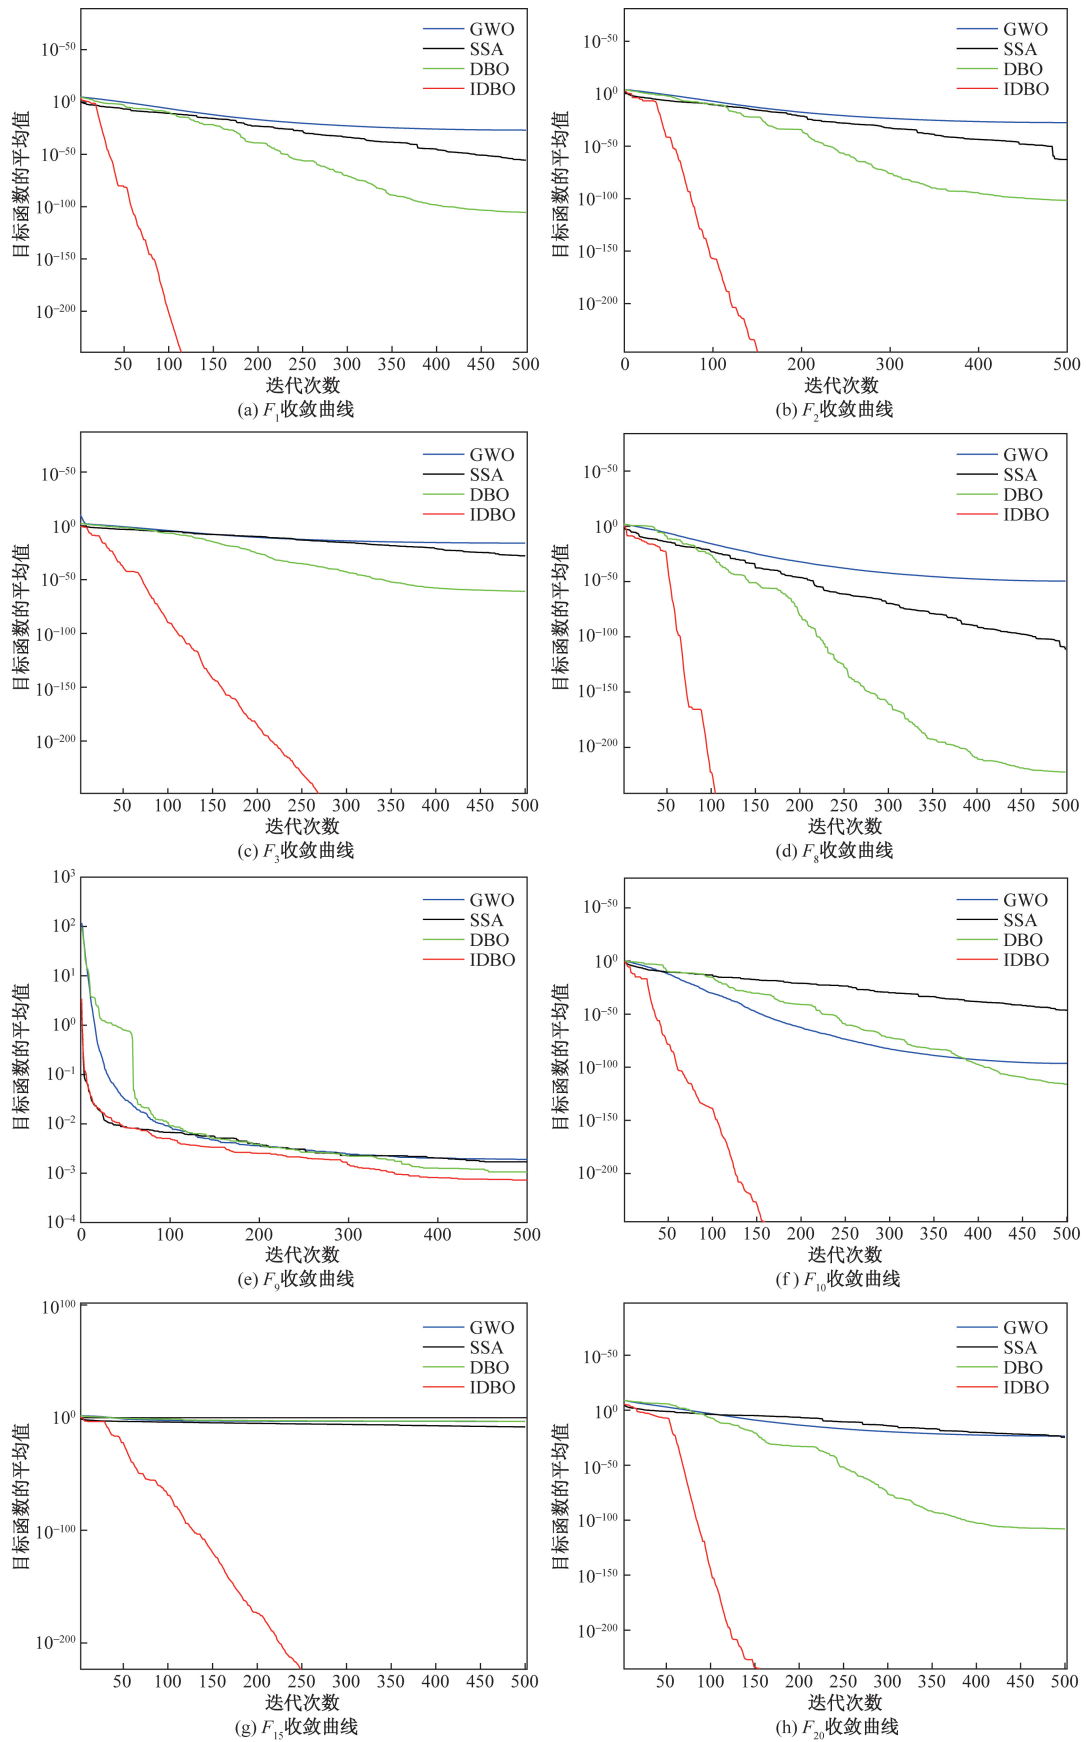


图2 不同函数值收敛曲线

Fig. 2 Convergence curves for different function values

3.2 冷水机组实验结果与分析

使用 ASHRE RP-1043 报告中冷水机组的运行数据作为实验数据集。实验系统共有冷冻水回路、冷却水回路、热水回路、城市供水和蒸汽供水 5 条回路,模拟了冷水机组的正常运行状态和 7 种典型故障类别,故障类型如表 3 所示。

另外 RP-1043 数据集对不同的故障划分了 4 个等级,依次由轻微到严重(SL1、SL2、SL3、SL4)。本文研究使用了最低故障等级 SL1 的数据作为样本,以更准确地反映冷水机组的运行和早期微故障问题。从表 3 的 7 种故障类型中各选取了 1 000 条,正常运行数据选取 4 000 条,共 11 000 条数据构建本文数据集样本,按 7:3 的比例划分为训练集和测试集。为避免数据特征对故障不敏感,后续影响实验准确度。本文研究选择了 16 个传感器成本较低且对故障敏感度较高的特征进行分析^[20]。

多分类混淆矩阵作为故障诊断的性能评估依据,具体如表 4 所示,其中字母 $a \sim i$ 表示分类的个数。根据该混淆矩阵,定义模型总体准确率(A_{cc})、单个类别故障诊断准确率(A_R)、误报率(F_{AR})、漏报率(U_R)。

故障模型总体准确率(A_{cc})定义为

$$A_{cc} = \frac{a + e + i}{a + b + c + d + e + f + g + h + i} \times 100 \quad (28)$$

以类别 1 为例,单个类别故障诊断 A_R 为

$$A_R = \frac{a}{a + b + c} \times 100 \quad (29)$$

单个类别的诊断 U_R 定义为

$$U_R = \frac{b + c}{a + b + c} \times 100 \quad (30)$$

单个类别的 F_{AR} 定义为

表 3 故障类型

Table 3 Types of failures

故障编号	故障类型	缩写
1	润滑油过量	EO
2	冷凝器结垢	CF
3	制冷剂泄露	RL
4	制冷剂过量	RO
5	不凝气体	NC
6	冷却水不足	FWC
7	冷冻水不足	FWE

表 4 混淆矩阵示意图

Table 4 Schematic diagram of the confusion matrix

类别	预测类			
	1	2	3	
真实类	1	a	b	C
	2	d	e	f
	3	g	h	i

$$F_{AR} = \frac{d + g}{a + d + g} \times 100 \quad (31)$$

为了验证本文所提出的故障诊断模型的有效性,设置了 3 个对照组: KELM、HKELM、DBO-HKELM。KELM、HKELM、DBO-HKELM、IDBO-HKELM 的混淆矩阵如图 3 所示,表 5 为各算法诊断不同故障类型的误报率(F_{AR})、漏报率(U_R)。

表 5 各诊断模型的故障诊断效果

Table 5 Fault diagnosis effects of each diagnostic model

状态种类	KELM		HKELM		DBO-HKELM		IDBO-HKELM	
	U_R /	F_{AR} /	U_R /	F_{AR} /	U_R /	F_{AR} /	U_R /	F_{AR} /
	%	%	%	%	%	%	%	%
NO	7.6	14.4	3.3	5	0.5	0.3	0.1	0.7
CF	8	16.1	1	2.9	0.3	0	0	0
EO	7.3	3.1	0	0	0	0	0	0
NC	11.3	7.6	1.3	1	0	0.3	0.3	0
FWC	37.3	14.2	16.7	9.1	1	1.3	2	1
FWE	0.3	0	0.3	0	0	0.3	0	0
RL	14	7.2	2.7	1	0.7	0	1	0
RO	0	1.6	0.3	2	0	1	0.3	0
准确率/%	90.54		96.76		98.92		99.71	

从表 5 可知, KELM、HKELM、DBO-HKELM 和 IDBO-HKELM 模型的准确率分别为 90.54%、96.76%、98.92% 和 99.71%, 可见 HKELM 比 KELM 具备更好的学习能力和泛化性能。其中经过 IDBO 优化后的 HKELM 模型准确率最高,较其他几种故障诊断模型分别提升了 9.17%、2.95%、0.79%。尤其针对 EO、FWE、RO 3 种故障类型, IDBO-HKELM 可达到 100% 准确率。这表明了经过本文改进的 IDBO 优化 HKELM 模型的准确性大幅提高,验证了 IDBO 具有良好的寻优能力,进一步证明了改进算法的优越性以及本文提出的 IDBO-HKELM 模型可以更好地针对冷水机组早期故障进行诊断分类。

4 结论

针对冷水机组早期故障的识别问题,提出了一种基于 IDBO-HKELM 的故障诊断方案,得出如下结论。

(1) 将 HKELM 与 KELM 进行实验对比,证明了 poly 核函数与 rbf 核函数相结合的 HKELM 提高了 KELM 的学习能力和泛化性能。

(2) 本文提出的融合 Bernoulli 混沌映射初始化、自适应惯性因子和 Levy 飞行融合动态权重系数策略的 IDBO 改进算法,通过基准函数测试,相较于改进前的 DBO 算法与 SSA 算法、GWO 算法收敛精度和速度得到明显优化。

(3) 通过 IDBO 算法对 HKELM 模型超参数的

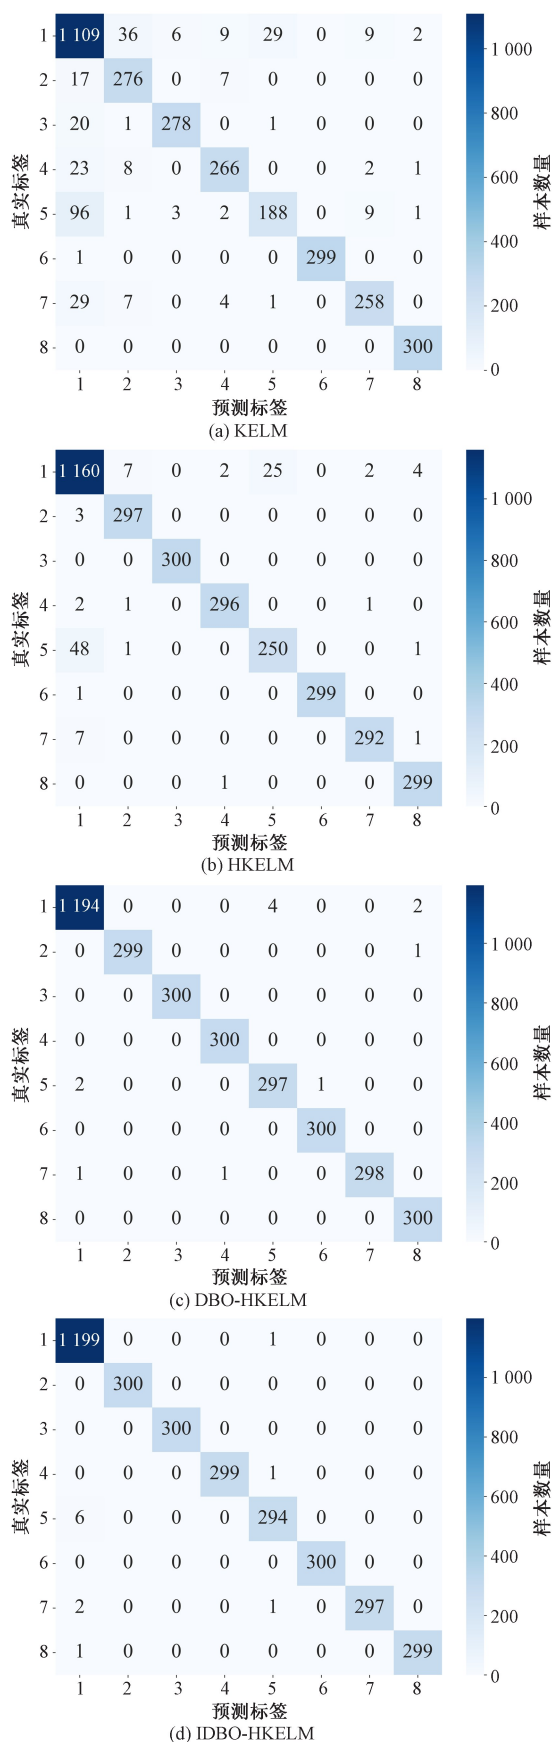


图3 各故障诊断模型混淆矩阵

Fig.3 Confusion matrix of each fault diagnosis model

优化,实验结果表明:本文设计的 IDBO-HKELM 的模型对冷水机组早期故障诊断的整体准确率达 99.71%;针对 EO、FWE、RO 3 种故障类型, IDBO-HKELM 可达到 100% 准确率。验证了本文方案在解决冷水机组故障分类性能上的有效性。

参 考 文 献

[1] Kim W, Katipamula S. A review of fault detection and diagnostics methods for building systems[J]. Science and Technology for the Built Environment, 2018, 24(1): 3-21.

[2] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.

Wen Chenglin, Lu Feiya, Bao Zhejing, et al. A review of data-driven methods for diagnosis of small faults[J]. Acta Automatica Sinica, 2016, 42(9): 1285-1299.

[3] 戴洪德, 张志亮, 崔伟成, 等. 基于 SSA-SVM 的航空电弧故障检测[J]. 科学技术与工程, 2024, 24(13): 5626-5633.

Dai Hongde, Zhang Zhiliang, Cui Weicheng, et al. Aerial arc fault detection based on SSA-SVM[J]. Science Technology and Engineering, 2024, 24(13): 5626-5633.

[4] 宋玉生, 刘光宇, 朱凌, 等. 改进的灰狼优化算法在 SVM 参数优化中的应用[J]. 传感器与微系统, 2022, 41(9): 151-155.

Song Yusheng, Liu Guangyu, Zhu Ling, et al. Application of improved GWO algorithm in SVM parameter optimization[J]. Transducer and Microsystem Technologies, 2022, 41(9): 151-155.

[5] 宋旭彤, 刘卓元, 金毅, 等. 基于 CNN 和预处理机制的球磨机故障诊断方法[J]. 传感器与微系统, 2022, 41(11): 134-137, 142.

Song Xutong, Liu Zhuoyuan, Jin Yi, et al. Fault diagnosis method for ball mill based on CNN and preprocessing mechanism[J]. Transducer and Microsystem Technologies, 2022, 41(11): 134-137, 142.

[6] 赵志宏, 李春秀, 窦广鉴, 等. 基于 MTF-CNN 的轴承故障诊断研究[J]. 振动与冲击, 2023, 42(2): 126-131.

Zhao Zhihong, Li Chunxiu, Dou Guangjian, et al. Bearing fault diagnosis method based on MTF-CNN[J]. Journal of Vibration and Shock, 2023, 42(2): 126-131.

[7] 吴经锋, 王文森, 张璐, 等. 基于 CNN 算法的并联电抗器机械故障诊断方法[J]. 电工电能新技术, 2022, 41(12): 72-80.

Wu Jingfeng, Wang Wensen, Zhang Lu, et al. Mechanical fault diagnosis method of shunt reactor based on CNN algorithm[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(12): 72-80.

[8] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks[J]. IEEE International Joint Conference on Neural Networks, 2004, 2: 985-990.

[9] Cambria E, Huang G B, Kasun L L C. Extreme learning machines[J]. IEEE Intelligent Systems, 2013, 28(6): 30-59.

[10] Deng C W, Huang G B, Xu J, et al. Extreme learning machines: new trends and applications[J]. Science China Information Sciences, 2015, 58(2): 1-16.

[11] Tang J, Deng C, Huang G B. Extreme learning machine for multi-layer perceptron[J]. IEEE Transactions on Neural Networks & Learning Systems, 2017, 28(5): 809-821.

- [12] 李花宁, 吴生彪, 冯丽, 等. 基于 AdaBoost-WOA-HKELM 的下肢关节角度预测[J]. 机电工程技术, 2024, 53(4): 36-40.
Li Huanning, Wu Shengbiao, Feng Li, et al. Lower limb joint angle prediction based on AdaBoost-WOA-HKELM[J]. Mechatronics Engineering Technology, 2024, 53(4): 36-40.
- [13] 赵鑫, 王东丽, 彭泓, 等. 基于多策略改进蜣螂算法优化的变压器故障诊断[J]. 电力系统保护与控制, 2024, 52(6): 120-130.
Zhao Xin, Wang Dongli, Peng Hong, et al. Transformer fault diagnosis based on multi-strategy improved dung beetle algorithm optimization[J]. Power System Protection and Control, 2024, 52(6): 120-130.
- [14] 范小虎, 赵爱罡, 许强, 等. 基于 ELM-SVR 模型的装备关键部件寿命预测[J]. 科学技术与工程, 2023, 23(2): 640-647.
Fan Xiaohu, Zhao Aigang, Xu Qiang, et al. Life prediction of key equipment components based on ELM-SVR model[J]. Science Technology and Engineering, 2023, 23(2): 640-647.
- [15] 宋永献, 王祥祥, 李媛媛, 等. 基于核极限学习机的下肢关节力矩预测方法[J]. 科学技术与工程, 2024, 24(11): 4599-4606.
Song Yongxian, Wang Xiangxiang, Li Yuanyuan, et al. A method for lower limb joint moment prediction based on nuclear limit learning machine[J]. Science Technology and Engineering, 2024, 24(11): 4599-4606.
- [16] 李彦阳, 王金东, 曲孝海. 基于 GMPE 和 GWO-MKELM 算法的往复压缩机轴承故障诊断[J]. 科学技术与工程, 2024, 24(23): 9842-9847.
Li Yanyang, Wang Jindong, Qu Xiaohai. Fault diagnosis of reciprocating compressor bearings based on GMPE and GWO-MKELM algorithms[J]. Science Technology and Engineering, 2024, 24(23): 9842-9847.
- [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.
- [18] 汤兆平, 孟鑫, 孙剑萍, 等. 基于改进鲸鱼优化算法的码垛机器人时间最优轨迹规划[J]. 科学技术与工程, 2024, 24(14): 5882-5891.
Tang Zhaoping, Meng Xin, Sun Jianping, et al. Time-optimal trajectory planning for palletizing robot based on improved whale optimization algorithm[J]. Science Technology and Engineering, 2024, 24(14): 5882-5891.
- [19] 王宏, 袁伯阳, 韩晨, 等. 基于机器学习的冷水机组早期故障诊断[J]. 低温与超导, 2023, 51(11): 96-102.
Wang Hong, Yuan Boyang, Han Chen, et al. Early fault diagnosis of chiller based on machine learning[J]. Cryogenics and Superconductivity, 2023, 51(11): 96-102.
- [20] Han H, Gu B, Wang T, et al. Important sensors for chiller fault detection and diagnosis(FDD) from the perspective of feature selection and machine learning[J]. International Journal of Refrigeration, 2011, 34(2): 586-599.