

基于改进 SSA-LSSVM 模型的 超声波氧气浓度在线估计方法

孙伟男¹, 刘瑜^{1†}, 扶艺辉¹, 陈昭克¹, 王明杰²

(1. 浙江理工大学信息科学与工程学院, 浙江 杭州 310018; 2. 杭州科兰铂科技有限公司, 浙江 杭州 311200)

摘 要:针对氧气浓度预测在样本数量较少时难以建立准确测量模型以及预测精度不高的问题,提出了一种基于改进麻雀搜索算法(ISSA)优化的最小二乘支持向量机模型(LSSVM)的超声波氧气浓度在线估计方法。首先针对麻雀搜索算法(SSA)易陷入局部最优的问题,引入改进 Sine 混沌映射优化种群初始参数,引入 Lévy 飞行策略对 SSA 跟随者位置更新方式进行改进。应用 4 种基准测试函数检验 ISSA 的性能,结果显示 ISSA 有效提升了收敛速度和寻优能力。然后构建 ISSA-LSSVM 超声波氧气浓度预测模型,基于实际数据的实验结果表明,ISSA-LSSVM 模型在氧气浓度预测中准确率达到 99.87%,验证了所提出方法的有效性。

关键词:氧气浓度预测;改进麻雀搜索算法;最小二乘支持向量机;改进 Sine 混沌映射;Lévy 飞行策略

中图分类号:TP18

文献标识码:A

Online Estimation Method of Ultrasonic Oxygen Concentration Based on Improved SSA-LSSVM Model

SUN Weinan¹, LIU Yu^{1†}, FU Yihui¹, CHEN Zhaoke¹, WANG Mingjie²

(1. College of Information Science and Engineering, Zhejiang Sci-Tech University, Hangzhou, Zhejiang 310018, China;

2. Hangzhou Kelanbo Technology Co., Ltd., Hangzhou, Zhejiang 311200, China)

Abstract: To address the issues of difficulty in establishing accurate measurement models and low prediction accuracy in oxygen concentration prediction when dealing with limited sample sizes, an online estimation method for ultrasonic oxygen concentration is proposed, which is based on the optimized least squares support vector machine (LSSVM) model using an improved sparrow search algorithm (ISSA). Firstly, to address the problem of sparrow search algorithm (SSA) easily falling into local optima, an improved Sine chaotic mapping is introduced to optimize the initial parameters of the population, and the Lévy flight strategy is applied to improve the position update method of SSA followers. The performance of ISSA is tested using four benchmark test functions, and the result shows that ISSA effectively improves the convergence speed and optimization ability. Then, an ISSA-LSSVM ultrasonic oxygen concentration prediction model is constructed. Experimental results based on actual data indicate that the accuracy of the ISSA-LSSVM model in oxygen concentration prediction reaches 99.87%, verifying the effectiveness of the proposed method.

Key words: oxygen concentration prediction; improving sparrow search algorithm; least squares support vector machine; improving Sine chaotic mapping; Lévy flight strategy

氧气作为人类赖以生存的必要气体和工业生产中的重要气体,在现代工业生产等诸多场景中对氧气浓度的检测是一项重要工作^[1]。随着超声波检测技术的不断发展,气体浓度的超声波检测法突破了传统检测方法的弊端,具备精度高、稳定性强等优势^[2]。

在气体浓度的预测领域,国内外学者提出了多种预测方法,Zhang 等^[3]使用 BP 神经网络来预测煤矿中氧气浓度和温度的分布情况,取得了较好的效果。郁永斌等^[4]使用径向基函数(RBF)神经网络软测量模型来预测氧气浓度,由于其只考虑了温度和超声波传播时间对氧气浓度的影响,所以预测精度有限。Ji 等^[5]将支持向量机(SVM)运用于河流溶解氧的预测,取得了一定的效果。上述网络的预测结果对初始参数的选取具有很大的依赖性,不当的初始参数选取可能导致模型收敛速度慢、预测精度低等问题。

近年来,各种智能群体优化算法凭借收敛速度快、优化网络不需要手动选取初始参数等优点,在神经网络优化上得到广泛运用。李其操等^[6]将鲸鱼优化算法(WOA)和 RBF 结合构建温室温度预测模型,提升了温室温度预测准确率。Xue 等^[7]于 2020 年提出的麻雀搜索算法(Sparrow Search Algorithm, SSA),具有收敛速度快、寻优效果好等优点。李雅丽等^[8]针对近几年较为典型的一些群体智能算法,利用 22 个测试函数,从算法的精度、收敛速度和预测稳定性等方面进行了对比,结果显示麻雀搜索算法的性能在很多方面优于其他算法。但是 SSA 仍存在易陷入局部最优的问题^[9]。

综上所述,提出了一种基于改进麻雀搜索算法(Improving Sparrow Search Algorithm, ISSA)优化最小二乘支持向量机(Least Squares Support Vector Machines, LSSVM)的超声波氧气浓度在线估计方法。针对 SSA 易陷入局部最优的问题,采用改进 Sine 混沌映射和 Lévy 飞行策略进行优化,有效改善了此问题。采用 ISSA 对 LSSVM 的惩罚系数 γ 和核函数参数 σ 进行寻优,提升 LSSVM 的预测精度。通过与其他模型的对比实验,结果表明本文提出的方法在预测精度方面有较大提升。

1 相关理论

1.1 超声波检测原理

气体浓度超声波检测方法分为传播速度差法、

多普勒法和噪声法,而传播速度差法又包括 3 种检测方法,其中时差法以高精度和相对较低的技术难度而应用最广泛^[10],本文采用的便是时差法。时差法的关键是测量超声波通过管道正、反向的飞行时间(Time of Flight, TOF)。时差法测量超声波飞行时间的原理如图 1 所示。




图 1 时差法原理图

在管道两侧安装超声波压电换能器 A 和 B。由 A 发送超声波而 B 接收到的这段时间为超声波正向飞行时间 TOF_{up} ,反之为超声波反向飞行时间 TOF_{down} 。

1.2 最小二乘支持向量机模型

LSSVM 由标准支持向量机 SVM 优化改进而来,其具有收敛速度更快,拟合精度更高的优点^[11]。LSSVM 建模过程如下:

设定训练样本集 $D = \{(\mathbf{x}_i, \mathbf{y}_i), \mathbf{x}_i \in R^{n_1}, \mathbf{y}_i \in R\}$,其中 $\mathbf{x}_i$ 为输入向量; $\mathbf{y}_i$ 为输出向量。

利用非线性高维空间构建决策函数:

$$f(x) = \boldsymbol{\omega}^T \varphi(x) + b \quad (1)$$

式中, $\boldsymbol{\omega}$ 为权向量; $\varphi(x)$ 为映射函数; b 为偏置量。

根据极小结构风险原则,将目标函数转化为:

$$\begin{cases} \min J(\boldsymbol{\omega}, e) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{\gamma}{2} \sum e_i^2 \\ \text{s. t. } y_i = \boldsymbol{\omega}^T \varphi(\mathbf{x}_i) + b + e_i \end{cases} \quad (2)$$

式中, J 为损失函数; e_i 为误差; γ 为惩罚系数。

通过构造拉格朗日乘子 α_i 求得:

$$L(\boldsymbol{\omega}, b, e, \alpha) = J(\boldsymbol{\omega}, e) - \sum_{i=1}^N \alpha_i [\boldsymbol{\omega}^T \varphi(\mathbf{x}_i) + b + e_i - y_i] \quad (3)$$

式中, L 为拉格朗日函数。

对式(3)中 $\boldsymbol{\omega}$ 求偏导后求解方程组,最终得到 LSSVM 回归函数:

$$f(x) = \sum_{i=1}^N \alpha_i K(x, \mathbf{x}_i) + b \quad (4)$$

式中, $K(x, \mathbf{x}_i)$ 为核函数,本研究采用 RBF

核函数,其表达式如下:

$$K(x, x_i) = \exp\left(-\frac{x_i - x_j^2}{2\sigma^2}\right) \quad (5)$$

式中, σ 为核函数参数。

2 融合改进 Sine 混沌映射和 Lévy 飞行策略的麻雀搜索算法 (ISSA)

2.1 标准麻雀搜索算法

麻雀种群中共有 3 种身份分工:领导者、跟随者和警戒者,每种麻雀会按照自身的规则更新位置。适应度更优的麻雀将成为领导者,其职责是带领种群搜寻食物,领导者位置更新规则如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot i_{\max}}\right), R_2 < S_T \\ X_{i,j}^t + Q \cdot L, R_2 \geq S_T \end{cases} \quad (6)$$

式中, i 为麻雀编号, $i \in [1, n]$, n 为种群数量; $j = 1, 2, 3 \dots d$; $X_{i,j}^t$ 为第 t 次迭代中第 i 只领导者在第 j 维的位置; $\alpha \in (0, 1)$, 为随机数; $Q \in [0, 1]$, 为服从正态分布的随机数; L 为元素全为 1 的 $1 \times d$ 矩阵; R_2 为警戒值, S_T 为安全阈值。

跟随者在整个探索过程中会时刻监视领导者,比较领导者获得的食物是否更好,是则去与领导者竞争,否则执行式(7)。

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), i > \frac{n}{2} \\ X_P^{t+1} + |X_{i,j}^t - X_P^{t+1}| \cdot A^+ \cdot L, i \leq \frac{n}{2} \end{cases} \quad (7)$$

式中, X_P^{t+1} 为第 $t+1$ 次迭代全局最优位置; X_{worst}^t 为第 t 次迭代全局最差位置; A 为 1 行 d 列的矩阵, $A^+ = (AA^T)^{-1}$ 。

警戒者能够感知所处环境的变化,一旦察觉到危险,他们会随机行动,其位置更新规则如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \lambda |X_{i,j}^t - X_{\text{best}}^t|, f_i > f_g \\ X_{i,j}^t + P \cdot \left[\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon} \right], f_i = f_g \end{cases} \quad (8)$$

式中, X_{best}^t 为全局最优位置; λ 为步长参数; $P \in [-1, 1]$, 为随机数; f_i, f_g, f_w 分别为当前个体适应度、全局最优适应度、全局最差适应度; ϵ 为极小常数,以避免 $(f_i - f_w) + \epsilon = 0$ 。

2.2 改进 Sine 混沌映射优化麻雀种群

SSA 通过随机方式生成初始种群,这种方式有较大概率导致种群分布不均,遍历效果不佳,进而减少种群多样性,最终影响算法的收敛速度。


Sine 混沌映射模型是一种映射折叠次数无限的模型,相比于折叠次数有限的混沌模型更具有混沌特性。其表达式如下:

$$y_{t+1} = k \sin(\pi y_t) \quad (9)$$


式中, $y_t \in [0, 1]$, 为第 t 次迭代的混沌值; k 为混沌控制参数,且 $k \in (0, 1]$ 。传统 Sine 混沌映射迭代在空间上分布不均,因此,文献[12]提出一种改进 Sine 混沌映射,其表达式如下:

$$\begin{cases} d_{t+1} = \sin(\mu \pi d_t) \\ e_{t+1} = \sin(\mu \pi e_t) \\ y_{t+1} = (d_{t+1} + e_{t+1}) \bmod 1 \end{cases} \quad (10)$$

式中, μ 和 y 分别为改进后 Sine 混沌映射的控制参数和混沌值。改进前和改进后的 Sine 混沌映射分布如图 2 所示。



(a) 改进前



(b) 改进后

图 2 Sine 混沌映射分布

从图 2 中可以看出,改进前的 Sine 混沌分布两端密,中间较为稀疏,改进后的混沌映射在 $[0, 1]$ 内基本呈现均匀分布。因此通过在麻雀种群初始化阶段引入改进 Sine 混沌映射,可以增强种群的分布均匀性,有助于算法进行更全面的搜索,提

升算法的收敛速度和寻优性能。

2.3 Lévy 飞行改进麻雀寻优策略

Lévy 飞行是一种随机行为策略,每次行动都是方向与步长均随机,通过结合短距离的局部搜索和偶尔的长距离行走,能够保证局部搜索精度的同时有效地进行全局搜索。这种平衡使得算法具有更好的寻优性能^[13]。Lévy 飞行的随机轨迹如图 3 所示。




图 3 Lévy 飞行轨迹

在标准 SSA 中,当领导者迭代一定次数后适应度值仍保持不变时,此时跟随者就成了领导者,这导致算法容易陷入局部最优。为改善此问题,在式(7)中引入 Lévy 飞行策略,使得算法位置更新更加全面,提高算法的全局探索能力和快速跳出局部最优能力。改进后的跟随者位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ X_p^{t+1} + X_p^{t+1} \oplus \text{Levy}(d), & i \leq \frac{n}{2} \end{cases}$$

(11)

式中,⊕ 为点乘;Lévy 飞行策略公式如下:

$$\text{Levy}(d) = 0.01 \cdot \frac{r_1 \cdot \delta}{|r_2|^{\frac{1}{\eta}}}$$

(12)

式中, r_1 、 r_2 均为 $[0,1]$ 内的随机数, η 取值范围为 $(0,2]$,本文取值 1.5, δ 的计算方式如下:

$$\delta = \left[\frac{\Gamma(1+\eta) \cdot \sin(\pi\eta/2)}{\Gamma((1+\eta)/2) \cdot \eta \cdot 2^{(1-\eta)/2}} \right]^{\frac{1}{\eta}}$$

(13)

式中, $\Gamma(\cdot)$ 为伽马函数, $\Gamma(x) = (x-1)!$ 。

2.4 算法性能验证

为验证 ISSA 算法的性能,本文将 PSO、WOA 和 SSA 算法与 ISSA 算法进行对比。为保证一致性,设置 4 种算法相同的参数:种群数量为 20,搜索空间维度为 30,最大迭代次数为 1000。应用 4 种算法基准测试函数来检验 ISSA 的优化效果。测试函数如表 1 所示。每种函数独立运行 50 次,函数测试指标采用平均值(MEAN)、标准差(STD)和运行时间(TIME),测试结果如表 2 所示。

在表 2 中,通过对比平均值可以看出:无论是在单峰测试函数还是多峰测试函数测试中,ISSA 都能够在设定迭代次数内找到最优极值 0,而其他 3 种算法仅在多峰测试函数测试下能找到最优极值,这说明 ISSA 的寻优能力更强。通过对比标准差可以看出:ISSA 的 STD 最小,这说明 ISSA 的寻优能力更加稳定。通过对比运行时间可以看出:ISSA 在 4 种测试函数中的运行时间均为最短,这说明 ISSA 的收敛速度更快。


单峰函数的收敛曲线如图 4 所示,从图中可以看出,ISSA 总能以较快的速度收敛到最优极值 0,而其他算法的收敛速度均慢于 ISSA 且迭代期间多次陷入局部最优,不能收敛到最优极值 0。

表 1 算法基准测试函数


类型	编号	函数名称	函数表达式	维数	寻优区间	最优极值
单峰函数	F1	Sphere	$\sum_{i=1}^n x_i^2$	30	$[-100,100]$	0
	F2	Schwefel's Problem 1.2	$\sum_{i=1}^n \left(\sum_{j=1}^i x_j^2 \right)$	30	$[-100,100]$	0
多峰函数	F3	Generalized Rastrigin	$\sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	$[-5.12,5.12]$	0
	F4	Generalized Griewank	$\frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600,600]$	0

表 2 算法测试结果


编号	指标	PSO	WOA	SSA	ISSA
F1	MEAN	1.14E-19	8.59E-68	7.82E-193	0
	STD	-1.64E-11	-7.70E-35	1.51E-97	-6.43E-169
	TIME/s	1.17E-01	8.65E-02	5.39E-02	3.76E-02
F2	MEAN	2.11E-116	6.22E-156	2.69E-246	0
	STD	3.46E-55	7.89E-79	1.01E-131	5.81E-166
	TIME/s	1.35E-01	9.22E-02	7.09E-02	3.48E-02
F3	MEAN	0	0	0	0
	STD	-1.69E-08	2.46E-09	4.63E-09	4.08E-11
	TIME/s	1.06E-01	9.33E-02	5.12E-02	2.57E-02
F4	MEAN	0	0	0	0
	STD	3.60E-09	-1.89E-09	5.01E-09	8.10E-11
	TIME/s	9.33E-02	8.56E-02	4.34E-02	2.31E-02




(a) F1 收敛曲线



(a) F3 收敛曲线



(b) F2 收敛曲线



(b) F4 收敛曲线

图 4 单峰函数收敛曲线

图 5 多峰函数收敛曲线

多峰函数的收敛曲线如图 5 所示,从图中可以看出 ISSA 依然能很快收敛到最优极值,其他 3 种算法虽然也能收敛到最优极值,但速度较慢。

综上所述,通过 4 个基准函数的测试,可以得出结论:与 PSO、WOA、SSA 相比,ISSA 的寻优能力提升明显,稳定性更好,收敛速度更快,全局搜索能力更强,能有效解决算法陷入局部最优的问题,

验证了 ISSA 的可行性和优越性。

3 基于 ISSA-LSSVM 的超声波氧气浓度预测模型

基于 RBF 核函数的 LSSVM 模型的预测精度

很大程度上由惩罚系数 γ 和核函数参数 σ 决定,但是这两个参数的取值难以确定,从而影响模型预测精度^[14]。为了解决参数难以确定的问题,提高模型的预测精度,本文采用 ISSA 优化 LSSVM 模型的 γ 和 σ 。构建基于 ISSA-LSSVM 的超声波氧气浓度预测模型,构建流程如图 6 所示。




图 6 基于 ISSA-LSSVM 模型的超声波
氧气浓度预测流程

具体步骤如下:

- 1)参数初始化:引入改进 Sine 混沌映射优化 SSA 初始种群,并进行 SSA 相关参数设置。
- 2)计算适应度:计算所有麻雀各自的初始适应度 f_i ,依据 f_i 大小进行排序,得到最优适应度个体和最差适应度个体。
- 3)更新位置:首先更新领导者位置,其次引入 Lévy 飞行策略改进跟随者更新位置方式,最后更新警戒者位置,并计算更新位置后的麻雀适应度。
- 4)终止判断:终止条件为迭代次数达到设定次数或预测误差达到期望值。若达到终止条件,则输出全局最优参数,否则跳转至第 2 步。
- 5)数据处理:将原始超声波氧气浓度相关数据划分为训练集、验证集和测试集;再对数据进行归一化处理,以消除量纲差异对预测结果的影响。
- 6)训练与仿真:将处理后的超声波氧气浓度相关数据导入 ISSA-LSSVM 模型进行训练与仿真,验证模型性能。

4 实例分析及仿真

4.1 实例研究

通过对氧气浓度检测机理及性质的研究分析^[15],本研究设置如图 7 所示的数据采集平台,进行氧浓度预测相关变量的数据采集。




图 7 数据采集平台

数据采集平台的构成如下:

- 1)各浓度的标准氧气:通过按不同比例向管道内混合各个浓度的标准氧气,可以生成任意浓度的氧气,从而为本研究提供多个浓度数据样本。同时,通过控制向管道内注入氧气的总量来控制气体压力。
- 2)高低温度气压实验舱:温度和气压直接影响超声波传播时间,通过高低温度气压实验舱精确控制舱内的温度和气压。
- 3)超声波流量计:气体流速是影响超声波传播时间的另一重要因素,本研究采用艾迈斯半导体公司生产的高精度时间测量芯片 TDC-GP30 作为主控芯片来测量超声波飞行时间^[16]。
- 4)气压泵调节管道内的气体流速,压力传感器监测管道内的气体压力。
- 5)氧气浓度仪:采用某公司生产的高精度氧浓度仪 VT900A。通过该氧浓度仪记录管道内的真实氧气浓度数据。

以图 7 所示的数据采集平台采集的相关变量制作数据集:6 个输入变量及范围如表 3 所示。氧气浓度作为预测变量,范围是 10%~99.8%。

表 3 输入变量的范围

输入变量	最小值	最大值
TOF _{up} /ns	195094.5	243961.5
TOF _{down} /ns	195120.5	247177.0
环境压力/kPa	47.4	101.3
气体压力/kPa	98.0	183.3
管道温度/℃	-40.0	50.0
管道流量/(L/min)	0.0	6.3

数据集共 650 组数据,将其按 6:2:2 的比例划分训练集、验证集和测试集,其中训练集 390 组

数据,验证集和测试集均为 130 组数据。

4.2 评价指标

本文采用均方根误差 RMSE、平均绝对误差 MAE 和决定系数 R^2 ,对模型的性能进行评价。

RMSE:表示预测值与真实值对应点误差的平方和的均值再开根号,计算如下:

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

(14)

MAE:反映预测值与真实值之间误差的实际情况,计算如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

(15)

R^2 :反映模型对数据的拟合程度,其值在 0 到 1 之间,越大代表模型的拟合越准确,计算如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$


(16)

式(14)~式(16)中, $\hat{y}_i$ 为第*i*个预测值; y_i 为对应的真实值; n 为验证集的样本数量; $\bar{y}$ 为样本均值。


4.3 模型性能对比分析

为验证 ISSA-LSSVM 预测模型的有效性,采用 PSO-LSSVM 模型、WOA-LSSVM 模型和 SSA-LSSVM 模型与本文模型进行对比分析。为保持一致,上述模型的样本数据,输入变量和预测变量均相同。本研究基于 MATLAB 2023a 平台。


4 种模型预测效果对比如图 8 所示,可以看出:ISSA-LSSVM 模型的氧气浓度预测值与真实值之间误差最小,拟合效果明显优于其他 3 种模型,能够对氧气浓度进行精准预测。




(a) PSO-LSSVM 模型预测值与真实值对比



(b) WOA-LSSVM 模型预测值与真实值对比



(c) SSA-LSSVM 模型预测值与真实值对比



(d) ISSA-LSSVM 模型预测值与真实值对比

图 8 各模型预测结果对比

上述 4 种预测模型分别独立运行 50 次,对比各预测模型的 3 种性能评价指标(取 50 次的平均值),结果见表 4。

表 4 氧气浓度预测性能对比

Model	RMSE	MAE	R^2
PSO-LSSVM	3.7069	2.3547	0.9563
WOA-LSSVM	3.1563	1.8708	0.9613
SSA-LSSVM	2.0974	1.2680	0.9762
ISSA-LSSVM	1.0922	0.6215	0.9987

从表 4 可以看出,ISSA-LSSVM 模型的 RMSE 和 MAE 比其他 3 种模型的都小,且决定系数 R^2 最大,接近于 1,其拟合准确度(以 R^2 作为评判标准)达到了 99.87%。可以得出结论:ISSA-LSSVM 模型对氧气浓度的预测误差最小,拟合真实数据的准确程度最高,预测效果明显优于其他 3 种模型,验证了所提出方法的有效性。

5 结 论

针对 SSA 易陷入局部最优的问题,引入 Sine 混沌映射优化种群初始参数,引入 Lévy 飞行策略对跟随者位置更新方式进行改进,有效增强了算法的全局搜索能力以及抗局部最优能力。应用 ISSA 优化 LSSVM 模型的关键参数 γ 和 σ ,构建 ISSA-LSSVM 超声波氧气浓度预测模型。通过基于实际数据的实验,结果显示 ISSA-LSSVM 模型的预测精度最高,验证了所提出方法的有效性。

后续的研究工作可以从以下方面展开:深入剖析每个变量对氧气浓度的影响以及变量之间的相互影响,降低变量的复杂度和冗余度,探索更加精准高效的氧气浓度预测方法。

参考文献

[1] 丁攀,戚路宽,郭伟,等. 氧气浓度检测方法发展现状及展望[J]. 中国医学装备,2018,15(12):164—167.

[2] 黄帆,徐云帆. 超声波流量计在天然气检测中的应用[J]. 计量与测试技术,2023,50(7):81—83.

[3] ZHANG Y J, WU G G, XU H, et al. Prediction of oxygen

concentration and temperature distribution in loose coal based on BP neural network[J]. Mining Science and Technology (China),2009,19(2):216—219.

[4] 郁永斌,和卫星,张翔,等. 基于 RBF 神经网络软测量模型在超声氧浓度计的应用[J]. 仪表技术与传感器,2014(12):131—133+141.

[5] JI X, SHANG X, DAHLGREN R A, et al. Prediction of dissolved oxygen concentration in hypoxic river systems using support vector machine: a case study of Wen-Rui Tang river, China[J]. Environmental Science and Pollution Research, 2017,24:16062—16076.

[6] 李其操,董自健. 基于 WOA-RBF 的温室温度预测研究[J]. 现代计算机,2023,29(11):43—46+51.

[7] XUE J, SHEN B. A novel swarm intelligence optimization approach:sparrow search algorithm[J]. Systems Science & Control Engineering,2020,8(1):22—34.

[8] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用,2020,56(22):1—12.

[9] 回立川,李瑶,李欢欢,等. 多策略改进的麻雀搜索算法[J]. 辽宁工程技术大学学报(自然科学版),2023,42(6):722—732.

[10] 张锐. 基于时差法的超声波气体流量测量系统的设计与实现[D]. 西安:西安电子科技大学,2019.

[11] WANG H, HU D. Comparison of SVM and LS-SVM for regression[C]//2005 International Conference on Neural Networks and Brain. IEEE, 2005, 1: 279—283.

[12] 刘金源,葛继科,唐籍涛. 一种基于改进型 Sine 映射的快速混沌图像加密算法[J]. 重庆科技学院学报(自然科学版), 2020,22(5):75—80+90.

[13] 毛清华,张强,毛承成,等. 混合正弦余弦算法和 Lévy 飞行的麻雀算法[J]. 山西大学学报(自然科学版),2021,44(6): 1086—1091.

[14] 骆正山,徐龙寅,骆济豪,等. 改进 SSA-LSSVM 模型在埋地管道点蚀深度预测中的应用[J]. 安全与环境学报,2023,23(9):3115—3122.

[15] FUKUOKA H, INOUE M, KATO Y, et al. Gas concentration measurment using ultrasonic[C]//The 1st IEEE Global Conference on Consumer Electronics 2012. IEEE, 2012: 67—68.

[16] YAO S, YANG M, ZHANG P F, et al. A small diameter ultrasonic water meter with selfdiagnosis function and self-adaptive technology [J]. IEEE Access, 2021, 9: 80703 — 80715.