

DOI:10.19651/j.cnki.emt.2108057

基于改进麻雀算法优化 LSSVM 的再循环箱浆液密度预测模型

仝卫国 郭超宇 赵如意

(华北电力大学自动化系 保定 071003)

摘要: 湿式脱硫制浆系统中再循环箱浆液密度测量的准确性和实时性对脱硫过程的经济稳定运行有重要意义,提出了一种基于改进麻雀搜索算法优化(ISSA)最小二乘支持向量机(LSSVM)的再循环箱浆液密度预测模型。通过机理分析选出与浆液密度相关性较高的辅助变量并进行预处理,并利用PCA算法进行降维处理。在标准麻雀算法(SSA)中引入混沌映射以及自适应权重,提高种群分布均匀性并改善了算法搜索能力,用于优化LSSVM的关键参数,实现对浆液密度的精准预测。通过实际数据的仿真实验,结果表明,ISSA-LSSVM测量模型的平均绝对百分比误差(MAPE)、均方根误差(RMSE)及平均绝对误差(MAE)相比SSA-LSSVM分别降低了44.5%、43.8%、43.9%,预测精度明显优于改进前预测模型,具有一定的工程应用价值。

关键词: 脱硫;麻雀搜索算法;LSSVM;再循环箱浆液密度

中图分类号: TM73 文献标识码: A 国家标准学科分类代码: 510

Prediction model of slurry density in recycling tank based on LSSVM optimized by improved sparrow algorithm

Tong Weiguo Guo Chaoyu Zhao Ruyi

(Department of Automation, North China Electric Power University, Baoding 071003, China)

Abstract: Accuracy and real-time measurement of slurry density in recycling box in wet desulphurization pulping system are important for the economic and stable operation of desulphurization process, a prediction model of slurry density in recycling box based on improved sparrow search algorithm optimization (ISSA) least squares support vector machine (LSSVM) is presented. Secondary variables that are highly correlated with the slurry density are selected and preprocessed through mechanism analysis, and use PCA algorithm to reduce dimension. Chaotic mapping and adaptive weights are added to the standard sparrow algorithm (SSA), which improves the uniformity of population distribution and searching ability of the algorithm. It is used to optimize the key parameters of LSSVM and to achieve accurate prediction of serum density. The simulation results of actual data have shown that the average absolute percentage error (MAPE), root mean square error (RMSE), and mean absolute error (MAE) of ISSA-LSSVM measurement model are reduced by 44.5%, 43.8%, 43.9% compared with SSA-LSSVM, and the prediction accuracy is significantly better than that of the pre-improvement prediction model, which has some engineering application value.

Keywords: desulfurization; sparrows search algorithm; LSSVM; slurry density of recirculation tank

0 引言

石灰石浆液制备是湿法烟气脱硫工艺中的重要环节^[1]。制浆系统中再循环箱浆液密度的准确测量是提高制浆品质与效率的关键,而浆液品质直接影响到脱硫效率^[2-3]。传统密度测量方法存在一些问题,由于浆液粘度大,容易引起测量管路的堵塞,同时浆液对密度计冲刷磨

损非常严重^[4],导致测量结果误差波动大甚至引起密度计损坏,直接影响后续设备稳定运行。因此建立一个制浆系统再循环箱浆液密度的软测量模型,有利于提高脱硫过程的运行稳定性。

近年来,软测量技术得到了迅速的发展。目前主要的方法有神经网络、偏最小二乘回归、极限学习机、支持向量机等。神经网络存在易陷入局部最优,收敛速度慢等缺点。

偏最小二乘回归中变量之间的耦合程度影响预测精度。极限学习机的鲁棒性较差限制了其应用范围。支持向量机(support vector machine, SVM), 结构简单, 在解决小样本、高维非线性等复杂问题方面有较大优势^[5]。最小二乘支持向量机算法(least squares support vector machine, LSSVM)对 SVM 做出进一步改进, 简化了运算, 优化运行速度, 提高了泛化性。同时现有研究表明, 引入优化算法可以提高单一预测模型的性能。文献[6]通过利用由种群变异和邻域搜索延伸策略改进的鲸鱼算法(whale optimization algorithm, WOA)优化后的 LSSVM 改善了电力负荷预测的准确性。文献[7]利用混沌粒子群优化算法与 LSSVM 相结合应用于脱硫系统浆液 pH 值的软测量中, 提供了一种有效的实时测量手段。文献[8]将遗传算法(genetic algorithm, GA)与 LSSVM 相结合, 提高了输电线路覆冰负荷的预测精度。针对优化算法后期种群多样性减少、易陷入局部最优解等情况, 文献[9]利用自适应 t 分布, 增强了种群多样性。文献[10]为增加种群初始化的多样性, 引入混沌映射在搜索范围内生成初始值。文献[11]将惯性权重因子与加速因子的改变方式与三角函数相结合, 优化了算法的搜索能力。

标准麻雀搜索算法^[12](sparrow search algorithm, SSA)具有参数设置简单, 收敛速度快等优点, 但存在后期种群多样性减少、易陷入局部最优解的问题。因此, 本文提出了一种基于改进的麻雀算法优化(ISSA)的最小二乘支持向量机算法(ISSA-LSSVM), 在标准算法中引入 Logistic 混沌映射提高初始种群的分布均匀性, 同时引入自适应权重来改变算法在不同迭代次数时的搜索能力, 以改善算法性能, 并以电厂分散控制系统(distributed control system, DCS)数据库中采集的实际数据为例, 首先选择辅助变量进行预处理, 并利用主成分分析(principal component analysis, PCA)算法进行降维, 然后利用 ISSA 算法对 LSSVM 中的关键参数进行寻优, 使用最优参数进行密度预测, 最后将预测结果与其他算法进行比较, 验证本文方法的准确性, 为浆液密度预测提供一种有效方法。

1 最小二乘支持向量机(LSSVM)原理

传统 SVM 模型中约束条件为不等式, 而 LSSVM 将 SVM 中的约束条件改为等式约束, 把误差平方和作为经验损失, 将求解凸二次规划的问题转换为了通过求解线性方程组^[13-14], 降低了求解难度, 优化了整体运算速度。

设定训练集 $\{x_i, y_i\}_{i=1}^n$, 其中 $x_i \in \mathbf{R}^d$ 为输入变量, y_i 为第 i 个输出, $y_i \in \mathbf{R}$, 通过非线性函数 $\varphi(\cdot)$ 将输入的 n 维空间映射到对应的高维特征空间, 因此 LSSVM 的回归估计函数为:

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

式中: $\boldsymbol{\omega} = [\omega_1, \omega_2, \dots, \omega_n]^\top$ 表示超平面权值系数向量; b 为偏置量。

LSSVM 定义优化问题目标函数 J 及其约束条件为:

$$\begin{cases} \min J(\boldsymbol{\omega}, \mathbf{e}) = \frac{1}{2} \boldsymbol{\omega}^\top \boldsymbol{\omega} + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \\ \text{s. t. } y_i = \boldsymbol{\omega}^\top \varphi(x_i) + b + e_i \end{cases} \quad (2)$$

式中: γ 为正则化参数, $\mathbf{e} = [e_1, e_2, \dots, e_n]^\top$ 为误差向量, e_i 为误差, $e_i \in \mathbf{e}$ 。

为求解上述优化问题, 构造相应的拉格朗日函数, 进行如下变换:

$$\begin{aligned} L(\boldsymbol{\omega}, b, \mathbf{e}, \boldsymbol{\alpha}) &= \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 - \\ &\sum_{i=1}^n \alpha_i (\boldsymbol{\omega}^\top \varphi(x_i) + b + e_i - y_i) \end{aligned} \quad (3)$$

式中: $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_n]^\top$ 为拉格朗日向量, α_i 是拉格朗日乘数, $\alpha_i \in \boldsymbol{\alpha}$; $\|\boldsymbol{\omega}\|$ 为对 $\boldsymbol{\omega}$ 求范式。

对式(3)中 $\boldsymbol{\omega}$ 、 b 、 \mathbf{e} 、 $\boldsymbol{\alpha}$ 的分别求偏导, 令导数为 0, 消除 $\boldsymbol{\omega}$ 和 e_i , 可得到线性方程组:

$$\begin{bmatrix} 0 & \mathbf{E}^\top \\ \mathbf{E} & \boldsymbol{\Omega} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (4)$$

式中: \mathbf{I} 为单位阵, $\mathbf{y} = [y_1, y_2, \dots, y_n]^\top$, $\boldsymbol{\Omega}$ 为核映射矩阵, $\boldsymbol{\Omega}_{i,j} = \varphi(x_i)^\top \varphi(x_j) = K(x_i, x_j)$, $\mathbf{E} = [1, 1, \dots, 1]^\top$ 。

最终得到 LSSVM 回归函数:

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (5)$$

本文中采用径向基(radial basis function, RBF)核函数, 与其他核函数相比, RBF 核函数能够实现非线性映射, 且需计算的参数较少, 其表达式为:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (6)$$

式中: σ 为核函数参数。

2 麻雀搜索算法

2.1 标准麻雀算法

算法运算过程由探索者、追随者与预警者 3 部分构成, 其中探索者与追随者的总数量与比例不变, 根据适应度数值的改变, 两者可以相互转化。通过觅食和反捕食行为来不断更新种群成员最优位置。

设种群数量为 n , 在第 K 次迭代中, 探索者的位置更新方式如下:

$$x_{i,p}^{k+1} = \begin{cases} x_{i,p}^k \cdot \exp\left(\frac{-i}{\alpha \times T}\right), & R_2 < ST \\ x_{i,p}^k + Q \cdot \mathbf{L}, & R_2 \geqslant ST \end{cases} \quad (7)$$

式中: $p = 1, 2, 3, \dots, d$; $x_{i,p}^k$ 为该次迭代中的第 i 个成员在第 p 维的位置; T 为最大迭代次数; $\alpha \in (0, 1]$; Q 是服从标准正态分布的随机数; \mathbf{L} 为元素均为 1 的 $1 \times d$ 矩阵; d 为待优化变量维数; R_2, ST 分别代表预警值和安全值。当 $R_2 < ST$ 时, 说明搜索范围附近没有危险, 搜索范围继续扩大, 反之搜索范围附近发现危险, 需要移动位置。

追随者的位置更新方式如下：

$$x_{i,p}^{k+1} = \begin{cases} Q \cdot \exp\left(\frac{xw_p^k - x_{i,p}^k}{i^2}\right), & i > \frac{n}{2} \\ xb_p^{k+1} + |x_{i,p}^k - xb_p^{k+1}| \cdot A^+ \cdot L, & \text{其他} \end{cases} \quad (8)$$

式中： xw_p^k 表示该次迭代的全局最差位置， xb_p^k 表示当前发现者的最优位置， A 为 $1 \times d$ 矩阵， $A^+ = A^\top (AA^\top)^{-1}$ 。适应度值低则需要移动位置进行觅食。

预警者在种群中的比例在 10%~20%，位置更新方式如下：

$$x_{i,p}^{k+1} = \begin{cases} x_{best}^k + \beta \cdot (x_{i,p}^k - x_{best}^k), & f_i > f_g \\ x_{i,p}^k + \lambda \cdot \left(\frac{|x_{i,p}^k - xw_p^k|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (9)$$

式中： x_{best}^k 是当前全局最优位置， β 为步长参数， $\beta \sim N[0,1]$ ， λ 是 $[-1,1]$ 之间的一个随机数，体现移动方向，加入极小常数 ϵ 避免计算中分母为 0， f_i 表示当前个体的适应度值， f_g, f_w 为当前种群最优适应度与最差适应度。

2.2 改进的麻雀算法

1) 引入 Logistic 混沌映射

初始种群分布质量将直接影响算法的性能，由于标准麻雀算法中，对种群及适应度初始化时，种群成员是在规定的搜索范围内随机生成的，这就造成了初始种群在搜索范围内的分布均匀性低，无法充分遍历解空间，极大影响了后续算法性能。

混沌运动具有随机性、规律性及遍历性^[15]，因此可以利用混沌映射来初始化种群成员，使其在搜索范围内分布更加均匀，Logistic 映射是具有代表性、应用较广泛的一类混沌映射模型，其数学表达式为：

$$y_{k+1} = \rho \cdot y_k \cdot (1 - y_k) \quad (10)$$

式中： $\rho \in [0,1]$ 为混沌映射系数， $y_k \in [0,1]$ 。

为了确定 ρ 的取值，分析了在不同 ρ 取值下 y_k 的分布情况如图 1 所示，以及 ρ 不变时 y_k 随初始值改变的分布情况如图 2 所示。

由图 1 可以分析得出，当 ρ 的取值接近 4 时， y_k 在 $[0,1]$ 内的分布均匀性上升，经过迭代生成的 y_k 呈现出一种伪随机分布的情况，相较于其他值，例如 $\rho = 2$ 时，迭代后 y_k 集中在 0.5 附近，并不符合需求。同时由图 2 可以分析得出，当初值改变时， y_k 的分布均匀性改变不大，初值选择对 y_k 影响很小。在本文中的混沌映射系数取 4，初值取 0.6。

引入混沌映射后的种群初始化公式为：

$$pop_n = y_k \cdot (u_b - l_b) + l_b \quad (11)$$

式中： y_k 为 $m \times n$ 矩阵， m 为初始化种群数量， n 为待优化参数个数； u_b, l_b 分别为待优化参数的上下限。

2) 引入自适应权重

随着搜索范围的改变，种群成员的搜索能力应相对变化^[16]，在迭代初期时，种群成员在较大范围内运动，需要较高的搜索能力在大范围内进行搜索，而随着算法的迭代，全

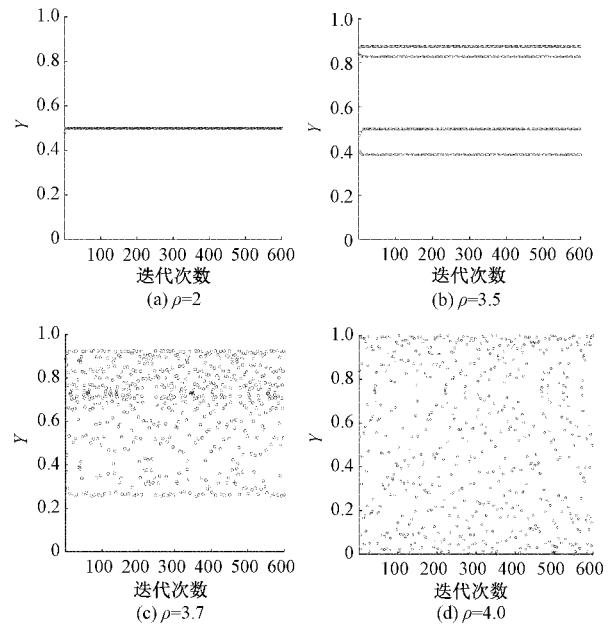


图 1 不同 ρ 取值时的 y_k 分布情况

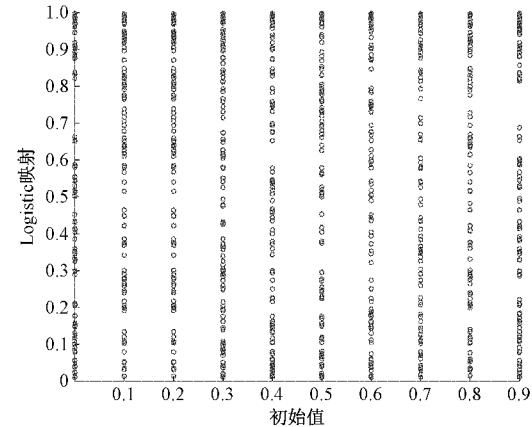


图 2 不同初值时 y_k 分布情况

局最优解的搜索范围不断减小，应增强算法的局部搜索能力。

综上，在探索者位置更新公式(7)中加入自适应权重因子，来优化算法性能。权重大大小随迭代次数而改变，在算法初期，权重较大，算法的全局搜索能力强且收敛速度快。当接近最优解时，权重较小可以在小范围内精确搜索。

$$x_{ip}^{k+1} = \begin{cases} x_{ip}^k + \omega \cdot \alpha(x_{ip}^k - f_g), & R_2 < ST \\ x_{ip}^k + Q \cdot L, & R_2 \geq ST \end{cases} \quad (12)$$

式中：自适应权重因子 $\omega = \cos((\pi \cdot k)/(2 \cdot T))$ 。

3 基于 ISSA-LSSVM 的浆液密度预测方法

3.1 辅助变量选择及数据预处理

湿式脱硫制浆系统的工件流程为：石灰石颗粒通过给料机输送至湿式球磨机中进行研磨后送入再循环箱，经循环泵输送至浆液旋流器后分为顶流与底流两部分，顶流进

入成品浆液箱,而底流部分则返回球磨机进行重新研磨。

通过对制浆系统的工作机理进行分析,对电厂DCS数据库中采集的各变量进行筛选,得到7个相关变量,分别为球磨机瞬时给料量、研磨水瞬时流量、稀释水瞬时流量、再循环箱液位、球磨机A相电流、再循环泵出口压力、旋流站入口压力。由于现场采集数据存在噪声、误差等情况,因此对数据进行预处理,步骤如下。

- 1) 利用插值法将数据中的缺失采样点补全。
 - 2) 去粗大值,将超出合理工况的数据剔除,提高模型预测准确性。
 - 3) 对于数据中所含噪声利用多元线性回归进行平滑去噪。
 - 4) 考虑到制浆系统中的时延问题,通过分析给料量、研磨水量、稀释水量等辅助变量的变化趋势与浆液密度变化趋势之间的关系,对原变量数据的时序进行了调整,进一步改善预测精度,并做归一化处理。
- 预处理后,通过PCA算法对相关变量的主成分贡献率进行计算,如表1所示提取4个主成分的累计方差贡献率已达到87.16%,完全可以代表原特征的绝大部分信息。

表1 PCA计算结果

主成分	特征值	方差贡献率	累计方差贡献率	权重
X1	3.103 1	44.324 2	44.324 2	0.470 2
X2	1.499 8	17.867 1	62.191 3	0.227 2
X3	1.001 7	12.563 9	74.755 2	0.151 8
X4	0.995 2	12.408 2	87.163 4	0.150 8

3.2 预测流程及模型建立

基于改进麻雀算法优化(ISSA)优化最小二乘支持向量机(LSSVM)的再循环箱浆液密度预测流程如图3所示。

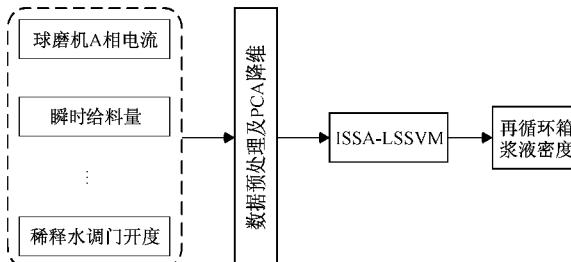


图3 浆液密度预测流程

LSSVM中正则化参数与RBF核函数参数对预测结果的准确性起着决定性作用,因此利用改进的SSA算法进行参数寻优,建立一个以再循环箱浆液密度为输出变量的软测量模型。建立预测模型的具体流程如图4所示,算法步骤如下。

- 1) 辅助变量选择及预处理,并利用PCA进行降维。
- 2) 初始化相关参数,利用改进的麻雀优化算法对LSSVM中的关键参数进行优化。

- 3) 初始化种群,利用式(11),引入Logistic映射,提升初始种群分布均匀性。
- 4) 根据目标函数计算适应度值并排序。利用引入自适应权重公式(12)更新探索者位置。
- 5) 利用式(8)及(9)更新追随者及警戒者位置。
- 6) 判断是否停止,执行退出或继续循环。
- 7) 输出正则化参数与RBF核函数参数,LSSVM利用最优超参数进行数据预测。

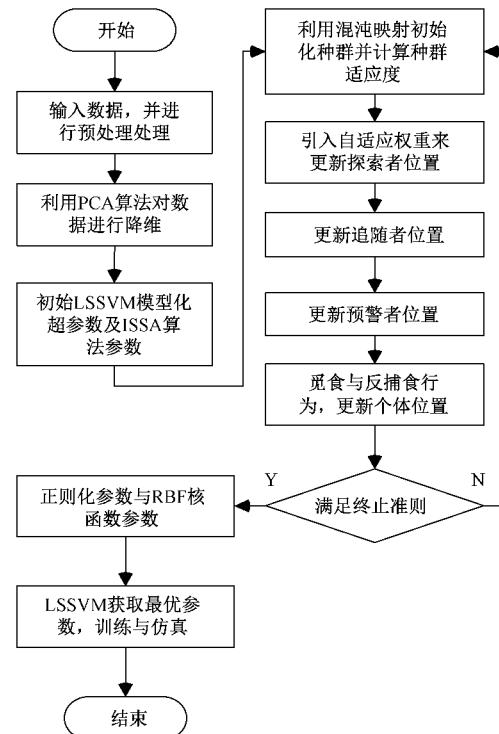


图4 ISSA-LSSVM算法流程

3.3 评价指标

为了使输出结果精度更加直观,本文引入评价指标如下。

- 1) 平均绝对百分比误差(mean absolute percentage error, MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^*}{y_i^*} \right| \times 100\% \quad (13)$$

- 2) 均方根误差(root mean square error, RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n}} \quad (14)$$

- 3) 平均绝对误差(mean absolute error, MAE)

$$MAE = \frac{\sum_{i=1}^n |y_i - y_i^*|}{n} \quad (15)$$

其中, y_i 为真实值, y_i^* 为模型输出值, n 为测试样本数。

4 实验及仿真

4.1 改进算法性能测试

为了测试改进后算法(ISSA)的性能,如表 2 所示,选取 6 个基准函数进行测试,测试时算法设置种群数 30,探索者与预警者占比为 20%,最大迭代次数为 200,维度为 30,各独自运行 20 次。在实验中引入均值与标准差作为性能衡量标准,均值反映了优化算法的准确度,而标准差可以反映化算法的稳定性与鲁棒性。

表 2 测试函数

测试函数	取值范围	最优解
$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
$F_2(x) = \max_i \{ x_i , 1 \leq i \leq n \}$	$[-100, 100]$	0
$F_3(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i$	$[-10, 10]$	0
$F_4(x) = \sum_{i=1}^n i x_i^4 + \text{random}[0, 1)$	$[-1.28, 1.28]$	0
$F_5(x) = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10)$	$[-5.12, 5.12]$	0
$F_6(x) = \sum_{i=1}^n \left(\sum_{j=1}^i X_j \right)^2$	$[-100, 100]$	0

不同函数测试结果如图 5 所示,对比迭代次数与适应度值,改进后的优化算法较原算法性能上有了较大地提升,在搜索前期,能够较快的对搜索范围进行遍历,有较高的搜索能力,提高了搜索效率,同时也保证了搜索的精度。

表 3 算法改进前后性能比较

函数	SSA		ISSA	
	均值	标准差	均值	标准差
F_1	2.3409×10^{-55}	1.2819×10^{-54}	2.1424×10^{-173}	0
F_2	1.8079×10^{-25}	9.8421×10^{-25}	8.2329×10^{-88}	2.5474×10^{-87}
F_3	1.2698×10^{-33}	4.8774×10^{-33}	1.4797×10^{-86}	6.0296×10^{-86}
F_4	0.0014	0.0012	5.7309×10^{-4}	6.2153×10^{-4}
F_5	0	0	0	0
F_6	2.0661×10^{-35}	1.1316×10^{-34}	3.9274×10^{-153}	3.9274×10^{-153}

4.2 实验结果与分析

选取天津某电厂所提供的 DCS 运行数据,数据采样间隔为 2 s。对所需数据进行预处理,最终确定 2 000 组数据用于模型仿真,其中 1 900 组数据用于模型训练,100 组数据用于测试。

1) 改进优化算法前后的结果对比

测试中种群数设置为 30,预警值为 0.8,探索者占比为 0.2,警戒者占比为 0.2,最大循环次数设置 100 次。

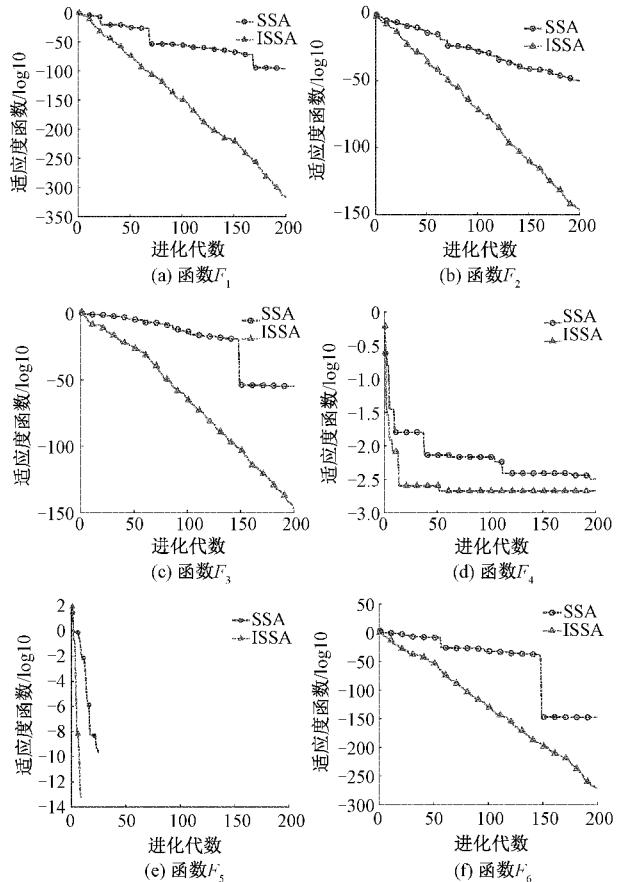


图 5 不同函数测试结果

改进前后性能比较结果如表 3 所示,由均值与标准差的数据对比可以更加直观得出,改进后的麻雀优化算法较原算法在精准度、稳定性及鲁棒性方面都有了较大地提升。

实际运行数据的仿真结果如图 6 所示。从图 6 中的实际浆液密度数据曲线可以看出原数据的波动较大,因此对模型的精度要求比较高。改进后算法在波谷处的预测效果明显好于标准算法。从图 7 预测误差对比可以看出,本文提出的 ISSA-LSSVM 模型在预测误差上较标准算法有了较大地提升,误差的波动范围明显减小,能够更好地反映浆液密度的变化。

如表 4 预测误差对比所示,改进后的软测量模型较原

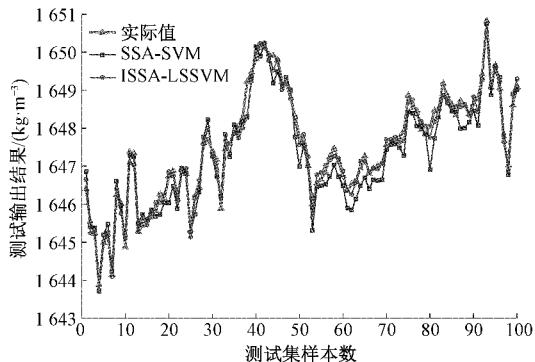


图 6 优化算法改进预测结果对比

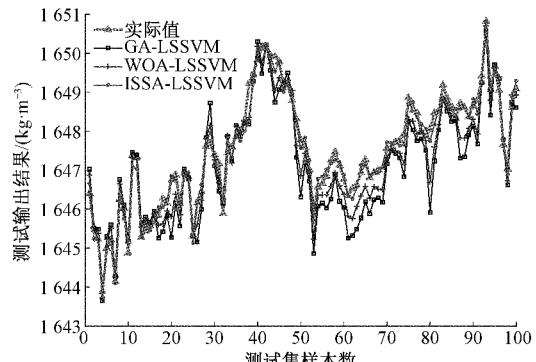


图 8 各预测模型结果对比

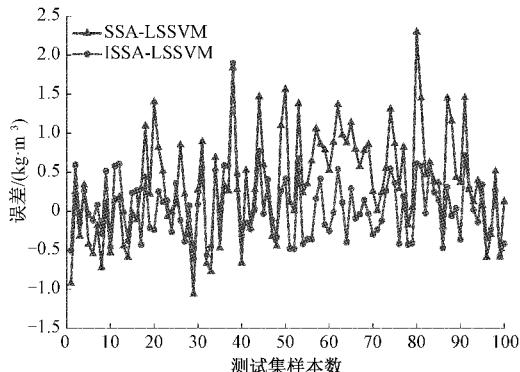


图 7 改进前后误差对比

软测量模型在 RMSE 方面减小了 44.5%, MAPE 减小了 43.8%, MAE 减小了 43.9%, 预测精度有了较大提升。综合各项指标可以得出, ISSA-LSSVM 软测量模型的预测效果优于未改进的软测量模型。

表 4 预测误差对比

模型	RMSE	MAPE/%	MAE
ISSA-LSSVM	0.412 8	0.201 2	0.331 0
SSA-LSSVM	0.743 7	0.358 3	0.590 2

2) 不同软测量模型的预测精度

为了比较本文提出的软测量模型的预测精度, 利用 GA 算法及 WOA 优化算法在同等实验条件下搭建了测量模型, 不同软测量模型的预测结果如图 8 所示。

通过预测结果对比可以发现, 其他两种方法在原数据波峰、波谷处的预测结果波动较大, 不能很好地反映出原数据变化情况。本文提出的 ISSA-LSSVM 模型在这种情况下一定程度上要优于其他两种模型。

各种模型的预测误差对比如表 5 所示。由表 5 数据可以分析得出, 在相同实验条件下, 本文提出的软测量模型与 GA-LSSVM 模型相比 RMSE 减小了 69.8%, MAPE 减小了 69.5%, MAE 减小了 69.5%。而对比 WOA-LSSVM 模型 RMSE 减小了 53.6%, MAPE 减小了 53.4%, MAE 减小了 53.7%。综合各种指标, 本文提出模型在预测精度

方面较其他两种模型均有优势。因此, 在比较了标准 SSA 优化 LSSVM、改进的 SSA 优化的 LSSVM 以及两种其他优化算法优化的 LSSVM 测量模型的预测结果后, 在预测精度方面本文提出的 ISSA-LSSVM 模型的预测效果最好。

表 5 各模型预测误差对比

模型	RMSE	MAPE/%	MAE
GA-LSSVM	1.364 8	0.659 6	1.085 5
WOA-LSSVM	0.889 8	0.434 4	0.715 6
ISSA-LSSVM	0.412 8	0.201 2	0.331 0

5 结 论

再循环箱浆液密度准确测量对湿式脱硫过程有重要影响, 为实现其在线准确测量, 提出了一种 ISSA-LSSVM 预测模型, 首先利用 PCA 算法对预处理后的辅助变量进行降维, 然后利用 ISSA 算法进行 LSSVM 的关键参数寻优, 最后利用最优参数进行密度预测。使用实际数据进行仿真实验, 结果表明: 1) 通过 PCA 主成分分析法对初始辅助变量进行降维, 提高了算法运行效率, 减少了过拟合的概率。2) 针对优化算法后期种群多样性减少、易陷入局部最优解的问题, 在其中引入 Logistic 混沌映射提高初始种群分布均匀性, 同时引入自适应权重来改变算法在不同迭代情况下的搜索能力, 提高了算法寻找全局最优解的能力, 将其与 LSSVM 相结合, 比较 SSA-LSSVM 及文中搭建的其他软测量模型, 在预测精度上有了明显提高, 预测效果良好。3) 针对系统中存在的时延问题, 应进一步提高对变量时序调整的精度, 以此作为今后研究的一个方向。

参考文献

- [1] 王世朋. 脱硫石灰石浆液密度计的应用与改进[J]. 电力科技与环保, 2016, 32(6): 32-33.
- [2] 李庆, 姜龙, 郭玥, 等. 燃煤电厂超低排放应用现状及关键问题[J]. 高电压技术, 2017, 43(8): 2630-2637.
- [3] 徐哲炜, 郑成航, 张涌新, 等. 基于改进关联规则算法的燃煤电厂脱硫系统工况参数优化[J]. 中国电机

- 工程学报, 2017, 37(15): 4408-4414,4581.
- [4] 胡晋波. 脱硫石灰石浆液密度差压法测量方式的改进及应用[J]. 华北电力技术, 2015(6): 58-61,65.
- [5] 谢波, 高建宇, 张惠娟, 等. 短期风电功率预测中的IOFA-SVM算法实现[J]. 电子测量技术, 2021, 44(12): 63-69.
- [6] 高金兰, 王天. 基于 VMD-IWOA-LSSVM 的短期负荷预测[J]. 吉林大学学报(信息科学版), 2021, 39(4): 430-438.
- [7] 乔宗良, 张蕾, 周建新, 等. 一种改进的 CPSO-LSSVM 软测量模型及其应用[J]. 仪器仪表学报, 2014, 35(1): 234-240.
- [8] 陈勇, 李鹏, 张忠军, 等. 基于 PCA-GA-LSSVM 的输电线路覆冰负荷在线预测模型[J]. 电力系统保护与控制, 2019, 47(10): 110-119.
- [9] 魏鹏飞, 樊小朝, 史瑞静, 等. 基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2021, 50(12): 74-79.
- [10] 张涛, 余利, 姚剑峰, 等. 基于改进多目标差分灰狼算法的配电网无功优化[J]. 信息与控制, 2020, 49(1): 78-86.
- [11] 贾会群, 魏仲慧, 何昕, 等. 基于改进粒子群算法的路径规划[J]. 农业机械学报, 2018, 49(12): 371-377.
- [12] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [13] 胡业林, 代斌, 宋晓. 基于小波包和 Δ FSA-SVM 的电机故障诊断[J]. 电子测量技术, 2021, 44(2): 48-55.
- [14] 殷礼胜, 唐圣期, 李胜, 等. 基于 EEMD-IPSO-LSSVM 的交通流组合预测模型[J]. 电子测量与仪器学报, 2019, 33(12): 126-133.
- [15] PICHAI S, SUNAT K, CHIEWCHANWATTANA S. An asymmetric chaotic competitive swarm optimization algorithm for feature selection in high-dimensional data [J]. Symmetry, 2020, 12 (11): 1782-1782.
- [16] 刘景森, 袁蒙蒙, 左方. 面向全局搜索的自适应领导者樽海鞘群算法[J]. 控制与决策, 2021, 36 (9): 2152-2160.

作者简介

全卫国, 博士, 副教授, 主要研究方向为先进控制策略在大型电力机组的应用、流量参数计量与检测新技术等。

E-mail:tongwg@ncepu.edu.com

郭超宇, 硕士研究生, 主要研究方向为机器学习、模型预测等。

E-mail:184082426@qq.com

赵如意, 硕士研究生, 主要研究方向为机器学习、参数预测等。

E-mail:1300975690@qq.com