

DOI:10.19651/j.cnki.emt.2005533

基于改进 PSO 优化 ELM 的高炉喷煤量预测研究

单宝明 薛永杰

(青岛科技大学 自动化与电子工程学院 青岛 266061)

摘要: 高炉炼铁过程中喷煤量的设定值通常由炉长经验得出,具有一定的盲目性和模糊性,为了增加喷煤量设定的合理性,提出了一种基于改进粒子群算法优化极限学习机的高炉喷煤量预测模型。基于某高炉实际运行数据,采用混沌惯性权重和自适应学习因子来改进粒子群优化(PSO)算法的收敛性,并通过引入遗传算法的交叉变异操作提高算法的全局最优性,然后利用改进的粒子群算法优化极限学习机(ELM)构建基于改进粒子群算法的极限学习机预测模型(IPSO-ELM)。最后,基于某高炉运行数据将所提出的 IPSO-ELM 预测模型与传统粒子群优化极限学习机预测模型(PSO-ELM),以及极限学习机预测模型进行比较。结果表明,该 IPSO-ELM 预测模型具有更高的预测精度,能够实现高炉喷煤量变化的准确预测,有较高的工业应用价值。

关键词: 喷煤量预测;改进粒子群算法;极限学习机;高炉

中图分类号: TF512 **文献标识码:** A **国家标准学科分类代码:** 450.35

Research on the prediction of coal injection rate of blast furnace based on improved PSO to optimize ELM

Shan Baoming Xue Yongjie

(College of Automation and Electronical Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: The setting value of the coal injection rate in the blast furnace ironmaking process is usually derived from the experience of the furnace manager, which has certain blindness and ambiguity. In order to increase the rationality of the coal injection rate setting, this paper proposes an improved particle swarm optimize the prediction model of blast furnace coal injection rate based on extreme learning machine. Based on the actual operating data of a blast furnace, this paper uses chaotic inertia weights and adaptive learning factors to improve the convergence of the particle swarm optimization (PSO) algorithm, and introduces the cross-mutation operation of genetic algorithms to improve the global optimality of the algorithm, and then uses the improvement. The particle swarm algorithm optimized extreme learning machine (ELM) builds an extreme learning machine prediction model (IPSO-ELM) based on the improved particle swarm algorithm. Finally, based on the operating data of a certain blast furnace, the IPSO-ELM prediction model proposed is compared with the traditional particle swarm optimization extreme learning machine prediction model (PSO-ELM) and the extreme learning machine prediction model. The results show that the IPSO-ELM prediction model has higher prediction accuracy, can achieve accurate prediction of the change of the blast furnace coal injection rate, and has high industrial application value.

Keywords: coal injection quantity forecast; improved particle swarm algorithm; extreme learning machine; blast furnace

0 引言

高炉炼铁系统十分复杂,保证炉内状况稳定很有必要^[1-2]。其中喷煤量的决策和控制是十分重要的因素。高炉炉长根据炉况基于个人经验每隔一段时间来确定喷吹煤粉量,由于高炉生产过程的复杂性和不同操作人员基于个人经验决策的差异性,仅凭人工对喷煤量的控制是粗糙和

主观的,具有较大的盲目性和模糊性。因此,根据高炉生产状况准确地做出高炉喷煤量预测具有重大意义。

传统的解析式建模方法很难建立精确的高炉喷煤量预测模型。近年来人工智能技术在国内外得到了广泛应用和快速发展。陈里里等^[3]构建一种基于堆栈稀疏自编码器和 Softmax 的神经网络来对液压泵泄漏状态进行识别的方法。杨成财等^[4]提出了一种基于支持向量机和能量最小

收稿日期:2020-12-13

化的极化 SAR 图像地物分类方法。曹泽卫等^[5]提出了一种基于卷积神经网络识别反馈的点阵字符检测方法。研究者开始采用智能技术建立高炉喷煤量预测模型。侯佳^[6]利用支持向量机建立基于炉温趋势的喷煤量预测模型,与 BP 神经网络相比,支持向量机克服了 BP 神经网络易陷入局部最优解、收敛速度慢等问题,提高了预测精度,但支持向量机识别能力易受自身参数影响,预测精度波动较大。Zhou 等^[7]提出基于 BP 神经网络和遗传算法的高炉喷煤量优化预测模型,优化了高炉喷煤的操作参数,但是需要设置的优化目标参数过多。崔佳梅等^[8]提出一种基于 T-S 模糊神经网络的喷煤量预测补偿模型,依据专家经验对不同炉况评价分级,预测修正喷煤量设定值使喷煤量与炉况相适应,但实验模型输入参数少,在炉况波动大时预测误差较大。

针对以上问题,提出一种基于改进粒子群算法(improved particle swarm optimization, IPSO)优化极限学习机(extreme learning machine, ELM)的高炉喷煤量预测模型,ELM 是 Huang 等在 2006 年提出的一种前馈神经网络^[9-10],有效地解决了反向传播算法学习效率低及参数设置繁琐的问题,但是 ELM 的输入权值和隐含层的偏置是随机产生的,它们的选取将对模型的预测精度产生影响,针对 ELM 这一问题,在传统粒子群的基础上引入混沌惯性权重、自适应学习因子以及粒子的交叉变异操作得到改进后的粒子群算法,用改进后的 PSO 优化 ELM 参数,得到满足训练目标的最优解,然后再利用优化后的 ELM 对高炉喷煤量进行预测。

1 数据预处理

在高炉冶炼过程中,由于生产过程并不是一直稳定的,受到生产条件、外部条件以及生产操作过程中人为因素的影响,收集的现场数据存在不完整甚至错误的数据,直接采用这些现场数据进行仿真实验,这将影响高炉喷煤量预测模型的精度,因此必须对采集使用的高炉现场数据进行分析处理。

1.1 数据筛选

本文选用某钢铁厂 3 号高炉 2019 年 1~3 月的生产数

据,根据专家经验选用影响高炉喷煤量的变量,删除与喷煤量无关的变量,得到 2 842 组数据作为初始样本集。

1.2 异常数据处理

根据工业现场参数需求,采用拉依达准则法对高炉喷煤现场采集筛选后的异常数据进行剔除,它的剔除原理是:高炉喷煤样本数据集 $x_i = (x_1, x_2, \dots, x_n)$, 样本平均值为 $\bar{x}$, 样本偏差为 $v_i = x_i - \bar{x}$, ($i = 1, 2, \dots, n$), 采用贝叶斯公式计算出数据集的标准差为:

$$s = \sigma = \left[\sum_{i=1}^n \frac{v_i^2}{n-1} \right]^{\frac{1}{2}} \quad (1)$$

若计算样本 x_i 的样本偏差 v_i ($1 \leq i \leq n$) 满足下式:

$$|v_i| > 3\sigma \quad (2)$$

则认为 x_i 是误差较大的异常值,对其进行剔除。对采集到的 2 842 组数据进行异常数据剔除,最后得到符合标准的 2 645 组数据作为高炉喷煤预测仿真初始样本集。

1.3 归一化处理

现场采集的高炉数据依据计算方式的不同存在不同的量纲,为了不影响数据仿真分析的结果,需要对数据归一化,对剔除异常值后的高炉数据集进行线性变换,采用的转换函数如下:

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3)$$

式中: X_n 代表归一化后的数据; X 代表原始数据; $X_{\max}$ 和 $X_{\min}$ 是采集的数据集中所用数据的最小值和最大值。最后对高炉喷煤量预测模型输出的结果进行反归一化操作。

1.4 相关性分析

高炉冶炼中影响喷煤量的参数很多,既受到煤粉自身燃烧率等冶炼条件的影响,又受到富氧量、风温、炉顶温度、铁水温度和透气性等参数的影响^[11]。如果在建模仿真中输入过多与喷煤量相关性较低的参数,容易使预测结果产生震荡,影响模型预测喷煤量的精度。本文采用 Pearson 相关分析法找到影响喷煤量较大的参数^[12]。选取与喷煤量相关性大于 0.3 的参数,如表 1 所示。与喷煤量 X_1 相关程度较大的有风量 X_2 、热风温度 X_3 、综合负荷 X_4 、压差 X_5 、密封室温度 X_6 、密封室氮气量 X_7 、炉腹煤气 X_8 和冷风温度 X_9 。选用这 8 个变量作为喷煤量预测模型的输入。

表 1 变量相关性分析

参数	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9
X_1	1	0.500	0.558	0.643	0.301	0.607	-0.414	0.702	0.630
X_2	0.500	1	0.412	0.522	0.368	0.355	-0.159	0.932	0.368
X_3	0.558	0.412	1	0.207	-0.053	0.275	-0.011 7	0.482	0.266
X_4	0.643	0.522	0.207	1	0.815	0.747	-0.549	0.648	0.773
X_5	0.301	0.368	-0.053	0.815	1	0.472	-0.370	0.408	0.505
X_6	0.607	0.355	0.275	0.747	0.472	1	-0.689	0.460	0.966
X_7	-0.414	-0.159	-0.011 7	-0.549	-0.370	-0.689	1	-0.269	-0.709
X_8	0.702	0.932	0.482	0.648	0.408	0.460	-0.269	1	0.481
X_9	0.630	0.368	0.266	0.773	0.505	0.966	-0.709	0.481	1

2 改进 PSO 优化 ELM 的预测模型

2.1 极限学习机

将高炉现场采集到的 N 个现场样本数据假设为 (x_i, y_i) , 其中 $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ 。那么有 L 个隐含层节点的 ELM 可以表示为:

$$o_j = \sum_{i=1}^L \beta_i h(\mathbf{W}_i \cdot \mathbf{X}_j + b_i), j = 1, 2, \dots, N \quad (4)$$

式中: β_i 为第 i 个隐含层节点到输出神经元的输出权重; $h(x)$ 为激活函数; $\mathbf{W}_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]^T$ 为输入神经元到第 i 个隐含层节点的输入权值; b_i 是第 i 个隐含层单元的偏置。ELM 的网络结构如图 1 所示。




图 1 ELM 网络结构

ELM 通过寻优得到的网络参数使输出的误差最小, 可表示为:

$$\sum_{j=1}^N \|\sigma_j - t_j\| = 0 \quad (5)$$

当激活函数 $h(x)$ 无限可微时, 存在 $\beta_i, \mathbf{W}_i$ 和 b_i , 使得:

$$\sum_{i=1}^L \beta_i h(\mathbf{W}_i \cdot \mathbf{X}_j + b_i) = t_j, j = 1, 2, \dots, N \quad (6)$$

可以简化表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (7)$$

其矩阵表达为:

$$\mathbf{H}(\mathbf{W}_1, \dots, \mathbf{W}_L; b_1, \dots, b_L; \mathbf{X}_1, \dots, \mathbf{X}_L) = \begin{bmatrix} h(\omega_1 x_1 + b_1) & h(\omega_2 x_1 + b_2) & \dots & h(\omega_L x_1 + b_L) \\ h(\omega_1 x_2 + b_1) & h(\omega_2 x_2 + b_2) & \dots & h(\omega_L x_2 + b_L) \\ \vdots & \vdots & \dots & \vdots \\ h(\omega_1 x_N + b_1) & h(\omega_2 x_N + b_2) & \dots & h(\omega_L x_N + b_L) \end{bmatrix} \quad (8)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_L^T \end{bmatrix}, \mathbf{T} = \begin{bmatrix} T_1^T \\ T_2^T \\ \vdots \\ T_N^T \end{bmatrix} \quad (9)$$

已经证明当 ELM 开始训练时, 在训练过程中输入权重 $\mathbf{W}_i$ 和隐含层的偏置 b_i 是不需要像 BP 神经网络每次都要进行计算调整的, 而是在开始训练前随机给出并且保持不变直到训练结束, 隐含层的输出矩阵 $\mathbf{H}$ 就会受到上述条

件的约束变成确定唯一的, 那么就可以通过求解线性方程组的方式获得输出权重 $\boldsymbol{\beta}$:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (10)$$

式中: $\mathbf{H}^+$ 是矩阵 $\mathbf{H}$ 的 Moore-Penrose 广义逆。

由于 ELM 的输入权值和隐含层的偏置是在高炉喷煤量预测模型训练前随机产生的, 并且输出矩阵是通过它们求解计算得到的, 使得高炉喷煤量预测输出结果具有很大随机性, 预测模型的不稳定性增加, 可能会造成某次预测结果和实际结果有很大偏差, 使得预测模型的精度有所波动和降低, 因此需要对采用的 ELM 进行优化提高^[13]。

2.2 改进粒子群算法

假设在 d 维的搜索空间内存在一个由 n 个粒子组成的种群, $x_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 表示第 i 个粒子的位置, $v_i = (v_{i1}, v_{i2}, \dots, v_{id})$ 表示第 i 个粒子的速度, $P_i = (P_{i1}, P_{i2}, \dots, P_{id})$ 表示粒子搜索的最优位置, $P_g = (P_{g1}, P_{g2}, \dots, P_{gd})$ 表示种群搜索的最优位置。粒子更新速度与位置的公式为:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id} - x_{id}^k) + c_2 r_2 (p_{gd} - x_{id}^k) \quad (11)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (12)$$

式中: k 表示粒子群算法循环迭代的次数; c_1 和 c_2 为学习因子; ω 为惯性权重系数; r_1 和 r_2 是在 $0 \sim 1$ 之间随机选取的。

由于将标准 PSO 算法直接应用到高炉喷煤量预测模型中容易陷入局部最优, 使得算法的寻优操作陷入停滞, 使得喷煤量的预测精度无法进一步提高^[14]。针对传统 PSO 算法在高炉喷煤量预测中存在的问题进行了如下 3 个方面的改进。


1) 引入一种新的混沌机制调整动态惯性权重, 采用一个随机数与指数型函数的乘积表示, 如式(13)、(14)所示。

$$\omega(k) = rand \cdot \omega_{\max} \left(\frac{\omega_{\min}}{\omega_{\max}} \right)^k \quad (13)$$

$$k = \frac{s^2 - 1}{S^2 - 1} \quad (14)$$

式中: $rand$ 是 $0 \sim 1$ 之间的均匀分布随机数; s 为粒子群算法的当前迭代次数; S 为粒子群算法的最大迭代次数。本文中设置 $\omega_{\max} = 0.8$, $\omega_{\min} = 0.4$, $S = 1000$, 得到改进的混沌动态惯性权重如图 2 所示。

从图 2 中可以看出, 在算法迭代开始时惯性权重取较大值的概率大, 使得粒子群算法发散, 从而增强了种群粒子的全局搜索能力, 随着迭代次数的增加, 惯性权重取较小值的概率大, 增强了种群粒子的局部搜索能力。总体而言, 随着迭代次数的增加, 惯性权重显示出下降的趋势, 但并不意味着下一迭代的惯性权重小于前一迭代的惯性权重。这样的惯性权重设置增加了粒子群的多样性, 并且不容易使粒子群陷入局部最优, 增强了粒子跳出局部最优的能力, 平衡了粒子全局寻优和局部寻优的能力。

图 2 混沌动态惯性权重 ω

2) 为了提高 PSO 算法的全局和局部学习能力, 引入自适应学习因子。在粒子寻优的初始阶段设置较大的学习因子, 以避免算法陷入局部最优, 随着 PSO 算法迭代次数的增加, 学习因子不断减小, 加快算法比较得出全局最优解。参数动态调整过程如式(15)、(16)所示。

$$c_1(s) = c_{1\max} - \frac{t}{T}(c_{1\max} - c_{1\min}) \quad (15)$$

$$c_2(s) = c_{2\min} + \frac{t}{T}(c_{2\max} - c_{2\min}) \quad (16)$$

式中: $c_{1\max}$ 、 $c_{1\min}$ 分别为学习因子 c_1 设定的上、下限; $c_{2\max}$ 、 $c_{2\min}$ 分别为学习因子 c_2 设定的上、下限。

3) 借鉴遗传算法中交叉和变异的思想^[15], 在粒子每次位置进行更新时以一定概率进行交叉变异操作, 用新产生的种群替代旧的种群继续寻优, 在算法迭代不断缩小种群搜索空间的同时保持种群多样性, 有效地增加粒子跳出局部最优的概率。

2.3 改进粒子群算法优化极限学习机

用上述改进的粒子群算法(IPSO)对 ELM 中输入层与隐含层间的连接权值和隐含层的阈值进行寻优, 从而得到 IPSO-ELM。改进粒子群优化 ELM 的流程如图 3 所示, 具体步骤如下:

1) 参数初始化。设置种群大小 n , 随机对各个粒子的初始位置 x_{i1} 和初始速度 v_{i1} 进行设定, 惯性权重的最大值 $\omega_{\max}$ 和最小值 $\omega_{\min}$, 学习因子 c_1 的上限 $c_{1\max}$ 和下限 $c_{1\min}$, 学习因子 c_2 的上限 $c_{2\max}$ 和下限 $c_{2\min}$, 迭代次数 S 等。

2) 计算粒子群初始适应度。使用训练样本的均方根误差作为适应度函数来计算每个粒子的初始适应度, 根据计算得到的适应度值找粒子群个体最优和全局最优粒子。

3) 更新粒子速度和位置。由式(13)、(14)计算得出混沌惯性权重 ω , 由式(15)、(16)计算得出学习因子 c_1 和 c_2 , 由式(11)、(12)更新粒子速度、位置。

4) 交叉和变异。设置概率交叉和变异每个粒子的位置, 得到新的种群, 根据新种群计算粒子适应度, 并与历史个体的最优位置和种群的最优位置进行比较, 选择较小的一个, 在进入下次迭代前替代成为新个体和种群最优

位置。

5) 检验终止条件。如果达到设置的最大迭代次数或精度要求, 则立即停止迭代寻优操作。否则返回步骤 2)。

6) 输出最优 ELM 参数。将得到的极限学习机输入层与隐含层间的连接权值和隐含层的阈值作为 IPSO-ELM 预测模型参数进行高炉喷煤预测研究。




图 3 改进粒子群优化 ELM 流程

3 算法仿真与结果分析

用改进后的 PSO 优化 ELM 并应用于高炉喷煤量预测模型中, 根据 1.4 的相关性分析, 选择 8 个参数作为输入层神经元, 分别为风量、热风温度、综合负荷、压差、密封室温度、密封室氮气量、炉腹煤气和冷风温度。输出变量为高炉喷煤量。

3.1 对比模型及评价指标

为了综合比较改进后的 PSO 优化 ELM 的高炉喷煤预测模型的性能, 本文选用多种评价指标: 平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)作为判断高炉喷煤量预测模型性能好坏的标准。各评价指标计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (18)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}}) \right]^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \quad (19)$$

式中: y_i 为喷煤量的实际值; $\hat{y}_i$ 为模型喷煤量预测值; $\bar{y}$ 为喷煤量真实值序列平均值; $\bar{\hat{y}}$ 为喷煤量预测值序列平均值; n 为样本数。

3.2 预测结果分析

为了检验本文提出的改进粒子群优化极限学习 (IPSO-ELM) 的高炉喷煤量预测模型的效果, 与标准粒子群算法优化极限学习机 (PSO-ELM) 预测模型、传统极限学习机 (ELM) 预测模型进行对照实验。经过对现场采集的高炉数据预处理后得到 2 645 个样本, 其中前 2 545 个样本作为训练集, 后 100 个样本作为测试集。各模型预测结果对比如图 4~6 所示, 预测误差对比如图 7 所示。




图 4 ELM 预测结果对比




图 5 PSO-ELM 预测结果对比




图 6 IPSO-ELM 预测结果对比

1) 相较于 ELM 预测模型, PSO-ELM 预测模型和 IPSO-ELM 预测模型拟合效果较好, 预测精度都有不同程度的提升, 表明粒子群算法在寻找最优参数方面具有更优




图 7 预测误差对比

的能力, 建立的喷煤量预测模型能够更好反映高炉炼铁过程中喷煤量的变化趋势, 获得更加理想的喷煤量预测结果对现场炉长调整参数具有较好的指导意义。

2) 相较于 PSO-ELM 预测模型, IPSO-ELM 预测模型具有更优的预测结果, 特别是一些炉次波动比较大的情况, 预测结果也能很好的反应实际的变化趋势, 主要是由于 IPSO 算法对惯性权重进行混沌惯性调整, 学习因子的自适应变化以及粒子的交叉变异操作, 改善了粒子群寻优的能力, 提升了高炉喷煤量的预测精度。

表 2 所示为预测样本为 100 炉次时各个模型多种评价指标。IPSO-ELM 预测模型与传统 ELM 预测模型相比, 评价指标 MAE 和 RMSE 分别降低了 62.54% 和 58.93%。IPSO-ELM 预测模型与 PSO-ELM 预测模型相比, 评价指标 MAE 和 RMSE 分别降低了 53.05% 和 50.55%。IPSO-ELM 预测模型与传统 ELM 预测模型和 PSO-ELM 预测模型相比决定系数 R^2 最大。因此本文建模方法相比 ELM 和 PSO-ELM 建模方法是可行有效的, 在高炉现场对炉长的实际操作具有较好的指导价值。

表 2 不用模型算法评价指标对比

模型	MAE	RMSE	R^2
ELM	0.975 8	1.192 2	0.936 0
PSO-ELM	0.778 5	0.990 1	0.959 3
IPSO-ELM	0.365 5	0.489 6	0.987 9

4 结 论

本文分析结合高炉冶炼生产过程的特点, 为了进一步提高高炉喷煤量预测模型性能, 在筛选优化样本数据的基础上, 针对 ELM 参数随机的问题上, 提出改进 PSO 算法对 ELM 参数优化, 并用其建立高炉喷煤量预测模型。在传统 PSO 的基础上引入混沌惯性权重、自适应学习因子以及粒子的交叉变异操作, 改善了传统 PSO 易陷入局部最优, 收敛速度慢等问题。实验结果表明, 提出的改进 PSO 优化 ELM 算法, 提高了高炉喷煤量预测的精度, 有较高的工业应用价值。为进一步提高模型预测精度, 接下来的工

作中将对模型激活函数进行改进,同时实现模型的在线预测。

参考文献

- [1] 陈建华,周平.高炉炼铁过程铁水质量的运行优化控制[J].控制工程,2020,27(7):1136-1141.
- [2] ZHOU P, GUO D W, CHAI T Y. Data-driven predictive control of molten iron quality in blast furnace ironmaking using multi-output LS-SVR based inverse system identification[J]. Neurocomputing, 2018, 308:101-110.
- [3] 陈里里,何颖,董绍江.基于深度神经网络的液压泵泄漏状态识别[J].仪器仪表学报,2020,41(4):86-94.
- [4] 杨成财,余慧庄,龙郝明.基于 SVM 和能量最小化的 PolSAR 图像分类方法[J].电子测量技术,2020,43(3):146-152.
- [5] 曹泽卫,欧阳,林冬婷,等.基于 CNNs 识别反馈的点阵字符检测方法[J].电子测量与仪器学报,2020,34(8):159-166.
- [6] 侯佳.基于炉温趋势的高炉喷煤量预测研究[D].包头:内蒙古科技大学,2015.
- [7] ZHOU H, YANG C, ZHUANG T, et al. Multi-objective optimization of operating parameters based on neural network and genetic algorithm in the blast furnace[C].第 36 届中国控制会议论文集(B),2017.
- [8] 崔桂梅,陈荣,马祥,等.基于高炉炉况评价和反馈补偿的喷煤量决策优化[J].控制与决策,2020,35(11):2803-2809.
- [9] 刘宇,廉洪波,王伟.基于改进 k-means 和 DE-ELM 的配电网负荷预测研究[J].国外电子测量技术,2019,38(5):45-49.
- [10] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems Man & Cybernetics Part B, 2012, 42(2):513-529.
- [11] 张宗旺,车晓锐,张宏博.高炉多目标优化模型的建立及验证[J].过程工程学报,2017,17(1):178-182.
- [12] 廖芹,郝志峰,陈志宏.数据挖掘与数学建模[M].北京:国防工业出版社,2010.
- [13] 关心.基于花朵授粉优化极限学习机的高炉铁水硅含量预测[J].电子测量技术,2020,43(4):77-80.
- [14] ZHANG X M, WANG X, KANG Q, et al. Differential mutation and novel social learning particle swarm optimization algorithm[J]. Information Sciences, 2018: 109-129.
- [15] DING Y, ZHOU K, BI W. Feature selection based on hybridization of genetic algorithm and competitive swarm optimizer[J]. Soft Computing, 2020, 24(1), DOI:10.1007/s00500-019-04628-6.

作者简介

单宝明,博士,副教授,主要研究方向为工业过程控制系统的建模、仿真与优化。

E-mail:shanbaoming@qust.edu.cn

薛永杰,研究生,主要研究方向为工业过程控制系统的建模、仿真与优化。

E-mail:xyjqust@hotmail.com