

DOI:10.19651/j.cnki.emt.2107444

基于改进 GWO-ELM 的热轧带钢卷取温度预测*

张 帅 王俊杰 李爱莲 崔桂梅

(内蒙古科技大学 信息工程学院 包头 014010)

摘要: 卷取温度控制精度是影响带钢产品性能的主要因素之一,提高卷取温度控制精度和保证卷取命中率是热轧领域的重点问题。针对某钢厂现有的卷取温度设定模型中存在个别钢种命中率低的问题,结合数据挖掘及现场专家经验,提出了一种基于灰狼优化极限学习机的新建模思路,并引入 Henon 映射、小孔成像策略和权重因子策略来改进灰狼算法,建立了基于改进灰狼优化极限学习机(IGWO-ELM)的热轧带钢卷取温度预测模型,并与 ELM 模型、GA-ELM 模型和 GWO-ELM 模型进行对比。模型结果表明:建立的 IGWO-ELM 模型,预测卷取温度在 $\pm 3\text{ }^{\circ}\text{C}$ 之内的命中率为 91.1%,在 $\pm 4\text{ }^{\circ}\text{C}$ 之内的命中率为 96.7%,均好于对比模型,具有广泛的实际应用前景。

关键词: 卷取温度预测;改进灰狼优化算法;极限学习机;热轧

中图分类号: TG335.56;TP183 **文献标识码:** A **国家标准学科分类代码:** 520.5060

Improved GWO-ELM based hot rolled strip coiling temperature prediction

Zhang Shuai Wang Junjie Li Ailian Cui Guimei

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: Coiling temperature control precision is the main elements influencing the presentation of strip steel items, and further developing curling temperature control exactness and guaranteeing winding hit rate is a main point of contention in the field of hot rolling. To resolve the issue of low hit pace of individual steel grades in the current coiling temperature setting model of a steel mill, a new modeling idea based on gray wolf optimized extreme learning machine is proposed combining data mining and field master insight, and Henon mapping, small-hole imaging strategy and weight factor strategy are introduced to improve the gray wolf algorithm, and a hot-rolled based on improved gray wolf optimized extreme learning machine (IGWO-ELM) is established. Strip coiling temperature prediction model based on the improved gray wolf optimized extreme learning machine (IGWO-ELM) and contrasted and ELM model, GA-ELM model and GWO-ELM model. The model results show that the established IGWO-ELM model has a hit rate of 91.1% for predicting the coiling temperature within $\pm 3\text{ }^{\circ}\text{C}$ and 96.7% for predicting the coiling temperature within $\pm 4\text{ }^{\circ}\text{C}$, both of which are better than the comparison models and have a wide range of pragmatic application prospects.

Keywords: coiling temperature prediction; improved gray wolf optimization algorithm; extreme learning machine; hot rolling

0 引 言

卷取温度控制是热连轧带钢生产线的重要环节,是决定带钢产品性能的主要因素之一^[1]。热连轧带钢层流冷却是一个复杂的非线性、强耦合等的过程,同时影响带钢卷取温度的参数较多且工艺复杂,使用机理模型很难精确描述。现如今深度学习在工业领域已初见端倪,例如:BP(back propagation)、支持向量机、极限学习机、集成学习等。例如:孙铁军等^[2]针对传统数学模型预测精度低的问题,提出了一种改进遗传算法优化 BP 的预测模型,将预报精度控

制在 $\pm 10\text{ }^{\circ}\text{C}$ 以内。卢广宇^[3]提出了一种基于小波神经网络的预测模型,相较于传统模型,预测精度更高。李子修等^[4]将 RBF(radial basis function)引入卷取温度预测,取得了良好的预测效果。梅文娟等^[5]将 ELM 模型用于器件退化趋势预测,相对传统预测模型,大大提高预测的精度。姚芳等^[6]将 GWO-ELM 模型用于逆变器故障诊断,通过仿真实验表明,有效提升了故障预测精确度。

本文以某钢厂 2250 热连轧生产线实际生产数据为样本,结合现场工艺和专家经验,对热连轧卷取温度预测模型

收稿日期:2021-07-30

* 基金项目:国家自然科学基金(61763039)项目资助

进行思考,通过输入参数相关性分析,提出了一种融合 Henon 映射、小孔成像策略和动态权重因子策略的改进灰狼优化算法(improved grey wolf optimizer, IGWO)优化极限学习机(extreme learning machine, ELM)的卷取温度预测模型,且与 ELM、GA-ELM^[6]、GWO-ELM 模型预测精度进行对比。结果表明,本文提出的 IGWO-ELM 模型卷取温度预测精度更高,能更好实现对卷取温度的高精度预测。

1 极限学习机

ELM 是一种基于前馈神经网络的机器学习模型,不需要调整结构参数就可以实现模型训练^[7]。与 BP、RBF 等相比,ELM 模型简单,泛化能力更强^[8,9],能更好克服过拟合等问题,因在回归预测方面的高效精确性能,被广泛应用于温度预测、价格分析等。

将热轧生产线采集到的 N 组样本数据假定为 $\{x_i, x_i\}$, 其中:

$$\begin{cases} x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n \\ t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m \end{cases} \quad (1)$$

则 ELM 输入输出可表述为:

$$\beta_j = \sum_{i=1}^L b_i h(w_i \times x_j + b_i) = t_j, j = 1, \dots, N \quad (2)$$

式(2)可用矩阵表述为:

$$H\beta = T \quad (3)$$

ELM 只需要确定权值 w_i 和阈值 b_i , 即可确定隐含输出,这样就将模型训练转化成线性方程 $H\beta = T$ 的求解问题,则:

$$\beta^* = H^+ T \quad (4)$$

其中, H^+ 为 H 的 Moore-Penrose 广义逆。

然而 ELM 的输入权值和隐含阈值随机设定,容易使模型的不稳定性增大,影响预测模型精度,所以需要加入优化算法对模型进一步优化。

2 灰狼优化算法

GWO 算法是一种新型的元启发式算法,灵感来自大自然中灰狼的内部制度和狩猎模式,通过模仿灰狼群体捕猎来达到寻优的目的。灰狼在自然界中处于食物链的上下游,喜欢集体生活,同时在灰狼内部严格执行等级制度^[10],如图 1 所示。




图 1 灰狼等级制度

其中, α 是灰狼种群中的头领,主要负责捕猎、食物分配等事务的决策; β 是 α 的辅助者和候选者,起着上传下达的作用,同时当 α 空缺时, β 就会接替 α 的位置; δ 听从 α 和 β 的命令,主要负责种群中基本的事务,例如站岗、侦查等;大多数的灰狼都属于 ω , 负责执行上层的命令和维持种群内部平衡。灰狼的捕食特征是集体捕食,主要包括围困、捕猎。首先在灰狼围困猎物中,将此行为用数学定义为:

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (5)$$

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (6)$$

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (7)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (8)$$

$$\vec{a} = 2 - \frac{2t}{t_{max}} \quad (9)$$

其中, \vec{X}_p 表示猎物位置信息; \vec{X}_i 表示灰狼所处位置; \vec{A} 和 \vec{C} 是系数向量; \vec{a} 表示距离收敛因子,变化幅度是从 2 线性减小到 0; \vec{r}_1 和 \vec{r}_2 是取值在 $[0, 1]$ 之间的随机数; t_{max} 表示种群最大迭代数。

此外,在灰狼捕猎中, β 和 δ 在 α 的带领下,更新狼群位置,数学定义如下:

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \end{cases} \quad (10)$$

$$\begin{cases} \vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \end{cases} \quad (11)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (12)$$

其中, \vec{D}_α 、 \vec{D}_β 和 \vec{D}_δ 分别是 α 狼、 β 狼和 δ 狼相对其他狼的位置向量; \vec{X}_α 、 \vec{X}_β 和 \vec{X}_δ 分别是 α 狼、 β 狼和 δ 狼的当前位置向量。

3 改进灰狼优化算法

为了改进 GWO 的开发能力、易陷入局部寻优和收敛精度低等问题,本文从 3 个方面对 GWO 改进。首先是采用 Henon 混沌映射初始化灰狼种群,提高算法的全局搜探能力,其次易陷入局部寻优是大多数优化算法的通病,针对这个问题,有学者提出了在算法改进中对最优值反向学习的方法^[11]。基于这个思想,本文引入小孔成像策略对最优值进行反向学习。最后是引入随机权重因子,动态平衡全局搜探和局部寻优。

3.1 Henon 混沌映射

混沌映射具有非线性、随机性和规律性等特点, Henon 映射效果优于 Tent 和 Logistic,不仅可以克服这两种映射的缺点,而且产生的序列更均匀,可以尽可能缩小搜索盲区,加快算法收敛速度,增强算法的寻优性能^[12]。所以本

文引入 Henon 映射来初始化灰狼种群。Henon 映射的数学描述如下所示^[13]。

$$\begin{cases} x_n = 1 - \alpha x_{n-1}^2 + \beta y_{n-1} \\ y_n = x_{n-1} \end{cases} \quad (13)$$

$$z'_i = \frac{x'_i - \beta_i}{\alpha_i - \beta_i}, i = 1, \dots, N \quad (14)$$

$$x'_i = lb_i + z'_i(ub_i - lb_i) \quad (15)$$

3.2 小孔成像反向学习策略

小孔成像是将一个带有小孔的板放置在光源和接收体中间,这时在接收体上就可形成光源形状的倒影,调节板与光源的距离,接受体上的成像大小随即改变,体现了光是直线传播的物理性质^[14]。原理如图 2 所示。




图 2 小孔成像原理

假定在空间中,存在一个高度为 h 的光源 g 在 X 轴上的投影为 X^i_{best} , 在原点 O 上放置一个带有小孔的小孔板,光源透过小孔在接收体上得到高度为 \hat{h} 的光源的倒影,同时也在 X 上产生一个反向点 \hat{X}^i_{best} , 由小孔成像原理得:

$$\frac{(a_i + b_i) - X^i_{best}}{2} - X^i_{best} = \frac{h}{\hat{h}} \quad (16)$$

然后令 $\frac{h}{\hat{h}} = k$, 得出:

$$\hat{X}^i_{best} = \frac{(a_i + b_i)}{2} + \frac{(a_i + b_i)}{2n} - \frac{X^i_{best}}{n} \quad (17)$$

当 $k = 1$ 时,得出:

$$X^i_{best} = (a_i + b_i) - X^i_{best} \quad (18)$$

与其他反向学习相比,小孔成像对灰狼算法的改进之处是对最优个体进行反向学习,得到各维度的反向值,扩展搜索范围,在每次迭代中,均通过式(16)进行重新搜寻,不断求得更优值,一直持续到迭代结束,从而改善算法性能。

3.3 动态权重因子策略

在基本 GWO 算法中,灰狼位置依靠头狼位置的均值来更新,当头狼位置并不是最优处时,随着算法迭代,其余灰狼不断靠近头狼,这时算法就会陷入局部寻优,所以引入一种权重因子来动态均衡灰狼算法全局搜探能力和局部寻优^[15-16],权重因子公式如下所示。

$$\gamma_1 = \frac{|\vec{A}_1 \cdot \vec{C}_1|}{|\vec{A}_1 \cdot \vec{C}_1| + |\vec{A}_2 \cdot \vec{C}_2| + |\vec{A}_3 \cdot \vec{C}_3|} \quad (19)$$

$$\gamma_2 = \frac{|\vec{A}_2 \cdot \vec{C}_2|}{\gamma_1 + |\vec{A}_2 \cdot \vec{C}_2| + |\vec{A}_3 \cdot \vec{C}_3|} \quad (20)$$

$$\gamma_3 = \frac{|\vec{A}_3 \cdot \vec{C}_3|}{\gamma_1 + \gamma_2 + |\vec{A}_3 \cdot \vec{C}_3|} \quad (21)$$

式中: γ_1, γ_2 和 γ_3 分别为灰狼其余个体对 3 只头狼的学习率。

最后,加入动态权重后的位置公式为:

$$\vec{X}(t+1) = \frac{\gamma_1 \vec{X}_1 + \gamma_2 \vec{X}_2 + \gamma_3 \vec{X}_3}{3} \quad (22)$$

3.4 改进灰狼算法实现步骤

步骤 1) 初始化灰狼算法基本参数: $N, t, k, t_{max}, a, \vec{A}, \vec{C}$;

步骤 2) 采用 Henon 混沌映射初始灰狼群体;

步骤 3) 计算灰狼个体适应度并进行排序;

步骤 4) 记录 $\vec{X}_\alpha, \vec{X}_\beta$ 和 \vec{X}_δ 位置,且确定 3 只头狼的适应度;

步骤 5) 根据式(17)对当前位置最好的个体 \vec{X}_α 进行小孔成像反向学习,生成反射解 $\hat{\vec{X}}_\alpha$, 计算反射解的适应度;

步骤 6) 若 $\hat{\vec{X}}_\alpha$ 适应度大于 \vec{X}_α 适应度,则用 $\hat{\vec{X}}_\alpha$ 代替 \vec{X}_α 进行算法迭代;

步骤 7) 根据式(9)计算 α , 通过式(19)~(21)计算 α, β 和 δ 权重,通过式(22)更新位置向量;

步骤 8) 根据式(7)~(8)更新 \vec{A} 和 \vec{C} 的值;

步骤 9) 更新 3 只头狼的适应度;

步骤 10) 算法若满足迭代条件则终止运行,输出最优解;反之,继续执行步骤 3。

3.5 改进灰狼算法性能测试

为了验证提出的 IGWO 算法的寻优效果,选择 CEC2005 中的 6 个基准函数来进行算法比较,且同时与 GA (genetic algorithm)、BOA (butterfly optimization algorithm)^[17]、GWO 算法进行对比。本次仿真环境为 Intel core i5, MATLAB R2018a。为了消除测试的偏差性,统一设置 $N = 30$, 基准函数维度为 30, 迭代次数为 1 000, 函数独立运行次数为 30 次^[18], 表 1 为函数信息^[19], 表 2 为函数测试结果。

表 1 函数信息

编号	函数名称	范围	最优	峰值
F1	Sphere	$[-100, 100]$	0	单峰
F2	Schwefel2.22	$[-10, 10]$	0	单峰
F3	Schwefel1.2	$[-100, 100]$	0	单峰
F4	Rastrigin	$[-5.12, 5.12]$	0	多峰
F5	Ackley	$[-32, 32]$	0	多峰
F6	Griewank	$[-600, 600]$	0	多峰

由表 2 数据可以看出, IGWO 算法的性能好于对比算法,从而可以证明 IGWO 改进策略的有效性。

表 2 函数测试结果

测试函数	指标	GA	BOA	GWO	IGWO
F1	Avg	5.35E+03	7.76E-10	2.86E-59	0.00E+00
	Std	4.04E+03	1.97E-10	4.78E-59	0.00E+00
F2	Avg	3.53E+01	1.51E-16	1.16E-34	0.00E+00
	Std	1.01E+01	7.69E-16	1.39E-34	0.00E+00
F3	Avg	4.04E+04	6.16E-10	9.68E-16	0.00E+00
	Std	1.12E+04	1.78E-10	2.61E-15	0.00E+00
F4	Avg	1.96E+02	0.00E+00	5.73E-01	0.00E+00
	Std	4.05E+01	0.00E+00	1.78E+00	0.00E+00
F5	Avg	1.97E+01	3.03E-07	1.62E-14	8.88E-16
	Std	5.14E-01	6.42E-08	3.51E-15	0.00E+00
F6	Avg	5.09E+01	7.73E-11	2.26E-03	0.00E+00
	Std	3.72E+01	1.23E-10	6.33E-03	0.00E+00

4 模型建立

4.1 建模数据处理

以某钢厂热轧生产线为研究对象,实地采集生产数据,但由于现场工况复杂、检测装置故障、人为因素等问题,采集到的数据容易存在偏差性和不一致性等问题,若直接将采集数据进行建模分析,会影响模型的准确度,所以必须对数据进行数据预处理。

首先通过 3σ 原则处理数据集中的异常值^[20],其次通过 SPSS 软件对模型输入参数进行相关性分析,选取相关性高的参数,同时为了减小数据量纲对模型精度影响,对实际生产数据归一化处理,结合现场专家经验,最终选取精轧出口温度、目标卷取温度、带钢运行速度、带钢宽度和带钢厚度为模型输入变量,实际卷取温度用来和预测卷取温度进行对比,预测卷取温度为模型输出变量。通过比较各节点数的均方误差得出最佳隐含层节点数为 25。卷取温度模型如图 3 所示,数据相关性分析如表 3 所示。

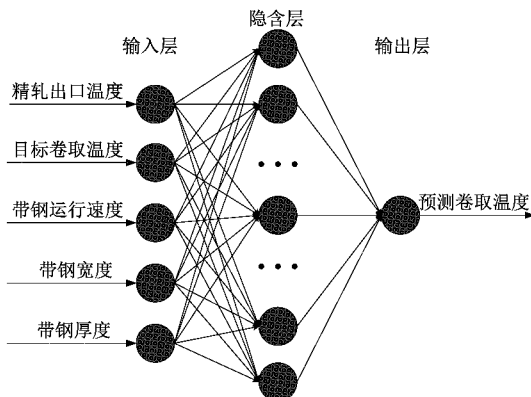


图 3 卷取温度模型

表 3 数据相关性分析

参数	实际卷取温度	
	Person 相关系数	样本数
精轧出口温度	0.611**	300
目标卷取温度	0.845**	300
带钢运行速度	0.562**	300
带钢宽度	-0.351**	300
带钢厚度	-0.626**	300

注:**. 在 0.01 级别(双尾),相关性显著。

4.2 预测结果分析

经过对实际生产数据预处理后,最终选择钢种为 Q235B,目标卷取温度为 660℃ 和 670℃ 的 300 组数据,分别选取其中的 70% 和 30% 作为训练集和测试集。为了模型的一致性,4 种模型采用同组数据,本文选择的各评价指标计算公式如下所示^[21]。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (23)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i| \quad (24)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y'_i - y_i|}{y_i} \quad (25)$$

其中, y_i 为实际卷取温度; y'_i 为预测卷取温度; n 为样本个数。模型评价结果如表 4 所示,各模型预测命中率如图 4~7 所示,模型预测曲线如图 8 所示。

表 4 模型评价结果

指标	ELM	GA-ELM	GWO-ELM	IGWO-ELM
RMSE	2.414 7	2.220 4	2.020 8	1.940 4
MAE	1.844 4	1.560 5	1.519 7	1.373 7
MAPE/%	0.275 8	0.233 4	0.227 3	0.205 4
±3℃/%	77.80	86.70	87.40	91.10
±4℃/%	87.80	92.20	94.50	96.70




图 4 ELM 模型命中率

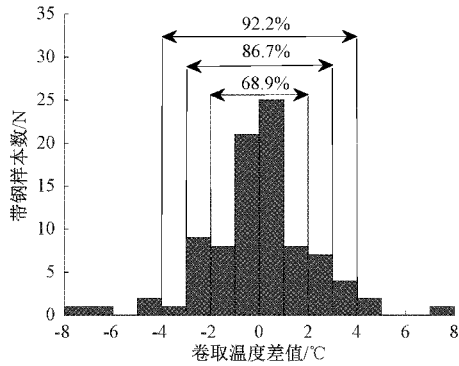


图 5 GA-ELM 模型命中率




图 7 IGWO-ELM 模型命中率




图 6 GWO-ELM 模型命中率

从表 4 可以看出,提出的 IGWO-ELM 模型相对于其他 3 种模型来说, RMSE、MAE 和 MAPE 均不同程度地降低,命中率进一步提高,表明了模型的有效性,也证明了提出的模型在卷取温度高精度预测中的可行性。

5 结 论

首先通过引入多种策略对算法进行改进,其次从热轧实际生产工艺角度出发,对建模数据进行相关性分析和预处理,最终通过模型预测结果可知,提出的 IGWO-ELM 预测模型的评价指标性能更优,在 $\pm 3\text{ }^{\circ}\text{C}$ 以内为命中率 91.1%,在 $\pm 4\text{ }^{\circ}\text{C}$ 以内命中率为 96.7%,更为精确地预测了

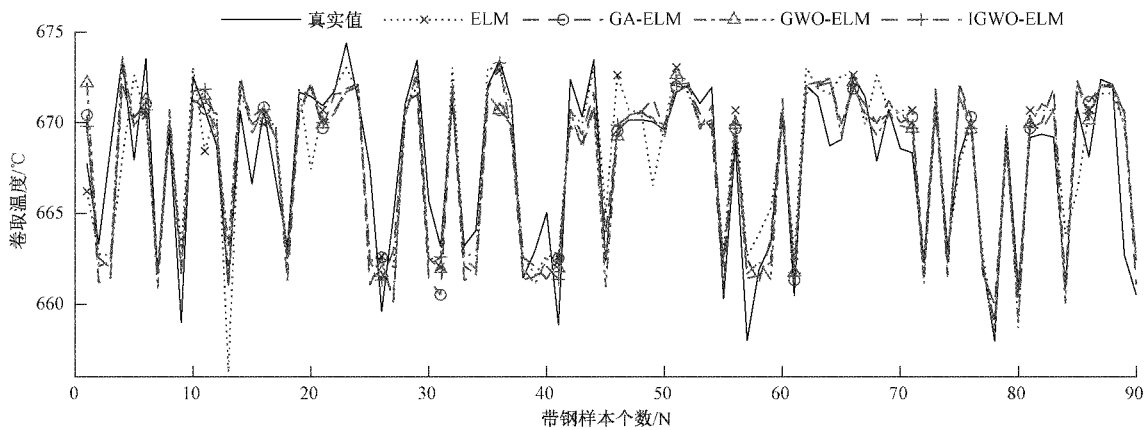


图 8 模型预测曲线

热轧带钢卷取温度,可以为热轧带钢实际生产设定模型建立提供全新思路,对热轧生产有很好的指导意义。

参考文献

[1] 孙铁军,杨卫东,程艳明,等.用改进遗传算法优化的带钢卷取温度预报模型[J].控制理论与应用,2015,32(8):1106-1113.
 [2] 卢广宇.基于小波神经网络的带钢卷取温度预测[D].沈阳:东北大学,2015.
 [3] 李子修,秦红波.基于 RBF 神经网络的层流冷却卷取温度预报[J].中国标准化,2018(14):215-216,219.
 [4] 梅文娟,高媛,杜立,等.基于在线相关熵极限学习机的

器件退化趋势实时流预测方法[J].仪器仪表学报,2019,40(11):212-224.

[5] 姚芳,姜涛,刘明宇,等.基于 GWO-ELM 的逆变器开路故障诊断[J].电源学报,2020,18(1):45-53.
 [6] 梅益,宋沛毅,陈丽娅,等.基于 GA-ELM 的机械手振动预测模型研究与应用[J].计算机仿真,2019,36(9):352-356.
 [7] HUANG G B,ZHOU H M,DING X J,et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B, Cybernetics: A

- Publication of the IEEE Systems, Man, and Cybernetics Society, 2012, 42(2):513-529.
- [8] 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.
- [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] 张晓凤, 王秀英. 灰狼优化算法研究综述[J]. 计算机科学, 2019, 46(3):30-38.
- [11] PARK S Y, LEE J J. Stochastic opposition-based learning using a beta distribution in differential evolution[J]. IEEE Transactions on Cybernetics, 2016, 46(10):2184-2194.
- [12] 谭光兴, 朱燕飞, 毛宗源. 基于 Hénon 映射的自适应克隆选择优化算法[J]. 计算机工程与应用, 2006, 42(9):73-76.
- [13] 李守玉, 何庆, 杜逆索. 混沌反馈共享和群体协同效应的蝴蝶优化算法[J/OL]. 计算机科学与探索, 2021:1-12. [2021-07-20]. <http://kns.cnki.net/kcms/detail/11.5602.TP.20210128.1109.014.html>.
- [14] 徐航, 张达敏, 王依柔, 等. 基于高斯映射和小孔成像学习策略的鲸鱼优化算法[J]. 计算机应用研究, 2020, 37(11):3271-3275.
- [15] 陈闯, CHELLALI R, 邢尹. 采用动态权重和概率扰动策略改进的灰狼优化算法[J]. 计算机应用, 2017, 37(12):3493-3497, 3508.
- [16] 郭振洲, 刘然, 拱长青, 等. 基于灰狼算法的改进研究[J]. 计算机应用研究, 2017, 34(12):3603-3606.
- [17] ARORA S, SINGH S. Butterfly optimization algorithm: A novel approach for global optimization [J]. Soft Computing, 2019, 23(3):715-734.
- [18] 徐辰华, 李成县, 喻昕, 等. 基于 Cat 混沌与高斯变异的改进灰狼优化算法[J]. 计算机工程与应用, 2017, 53(4):1-9, 50.
- [19] 肖辉辉, 段艳明, 林芳. 新搜索策略的花授粉算法[J]. 电子测量与仪器学报, 2019, 33(7):11-20.
- [20] 杨婧, 辛明勇, 欧家祥, 等. 基于拉依达准则的计量自动化系统数据准确性判断方法[J]. 电力大数据, 2017, 20(11):74-78.
- [21] 侯丽芳. 基于 IFSVR 和 PSO 算法的转炉炼钢终点预测[J]. 电子测量技术, 2021, 44(5):68-73.

作者简介

张帅, 硕士, 工程师, 主要研究方向为复杂过程建模与优化控制研究。

E-mail: 364776437@qq.com

王俊杰(通信作者), 硕士研究生, 主要研究方向为复杂过程建模与优化控制研究。

E-mail: 1414086605@qq.com