

4-14-2021

Load System Modeling of Ultra-Supercritical Coal-Fired Power Unit Based on Improved Particle Swarm Optimization

Yuzhen Sun

Research Center of Intelligent Management and Control for Power Process, College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

Yiwei Tang

Research Center of Intelligent Management and Control for Power Process, College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

Li Shuai

Research Center of Intelligent Management and Control for Power Process, College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Load System Modeling of Ultra-Supercritical Coal-Fired Power Unit Based on Improved Particle Swarm Optimization

Abstract

Abstract: Aiming at the difficulties in modeling due to variables coupling of ultra-supercritical coal-fired power unit and defects in basic particle swarm optimization, an *improved particle swarm optimization algorithm for modeling of load system is proposed*. The algorithm introduces the idea of adaptive, Cauchy mutation and gradient guidance crossover, which improves the problems of particle swarm optimization algorithm being prone to premature convergence and has the poor local searching ability. By collecting the actual operation data of the power plant, using the adaptive Cauchy mutation and gradient guidance cross particle swarm optimization (GMGPSO) algorithm, the model established and validated. The simulation results show that the model output obtained by the GMGPSO algorithm has a good effect on fitting the actual data on site. The average convergence speed and the average accuracy both are improved a lot.

Keywords

load system, system modeling, Cauchy mutation, gradient guidance crossover, PSO algorithm

Recommended Citation

Sun Yuzhen, Tang Yiwei, Li Shuai. Load System Modeling of Ultra-Supercritical Coal-Fired Power Unit Based on Improved Particle Swarm Optimization[J]. Journal of System Simulation, 2021, 33(4): 875-882.

基于改进粒子群算法的超超临界燃煤机组负荷系统建模

孙宇贞, 唐毅伟, 李帅

(上海电力大学 自动化工程学院 上海发电过程智能管控工程技术研究中心, 上海 200090)

摘要: 针对超超临界机组负荷系统因耦合度高导致的建模困难问题及基本粒子群算法存在的缺陷, 提出了一种用于负荷系统建模的改进粒子群算法, 通过引入自适应、柯西变异以及梯度指导交叉思想, 改善了粒子群算法容易产生早熟收敛、局部寻优能力较差等问题。将自适应柯西变异和梯度指导交叉粒子群算法与电厂的实际运行数据结合进行负荷系统建模和校验。仿真结果表明: 应用该算法辨识得到的模型输出拟合现场实际数据的效果较好, 算法的平均收敛速度和模型的平均精度较基本的粒子群算法有明显提升。

关键词: 负荷系统; 系统建模; 柯西变异; 梯度指导交叉; 粒子群算法

中图分类号: TP273A+4 A 文献标志码: A 文章编号: 1004-731X (2021) 04-0875-08

DOI: 10.16182/j.issn1004731x.joss.19-0649

Load System Modeling of Ultra-Supercritical Coal-Fired Power Unit Based on Improved Particle Swarm Optimization

Sun Yuzhen, Tang Yiwei, Li Shuai

(Research Center of Intelligent Management and Control for Power Process, College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Aiming at the difficulties in modeling due to variables coupling of ultra-supercritical coal-fired power unit and defects in basic particle swarm optimization, an *improved particle swarm optimization algorithm for modeling of load system is proposed*. The algorithm introduces the idea of adaptive, Cauchy mutation and gradient guidance crossover, which improves the problems of particle swarm optimization algorithm being prone to premature convergence and has the poor local searching ability. By collecting the actual operation data of the power plant, using the adaptive Cauchy mutation and gradient guidance cross particle swarm optimization (GMGPSO) algorithm, the model established and validated. The simulation results show that the model output obtained by the GMGPSO algorithm has a good effect on fitting the actual data on site. The average convergence speed and the average accuracy both are improved a lot.

Keywords: load system; system modeling; Cauchy mutation; gradient guidance crossover; PSO algorithm

引言

火电厂超(超)临界机组在运行过程中, 出现最多的扰动之一就是电网侧负荷的改变。当外界负荷变动时, 机组需要相应地调整出力来达到调节负荷的目的。负荷调整时, 机组主调门开度、总燃料量

和给水流量的变化会改变工质的吸热过程, 进而影响到中间点温度、主蒸汽压力等后续参数, 是典型的非线性多变量系统, 因此采用机理方式建立负荷系统模型的过程较为繁琐。近年来, 出现了很多采用智能算法代替传统机理建模方式来计算控制系统模型参数的方法^[1]。主要有采用神经网络、深度

收稿日期: 2019-12-13 修回日期: 2020-06-20

基金项目: 上海市重点实验室建设(13DZ2273800); 上海市科学技术委员会工程技术研究中心(14DZ2251100)

第一作者: 孙宇贞(1975-), 女, 硕士, 副教授, 研究方向为智能控制及电厂过程控制。E-mail: sunyuzhen@shiep.edu.cn

学习来建立非线性系统的数学模型^[2-3]；还有通过遗传算法、蚁群算法等智能算法来得到精度较高的数学模型的方法^[4-6]。将这些方法与解耦的热工系统结构模型相结合，免去了机理建模的繁琐过程，因此在电厂热工系统建模中得到了广泛应用。

本文采用的粒子群算法(PSO)是一种基于群体的智能进化计算方法。基本的 PSO 存在容易产生早熟收敛、局部寻优能力较差等问题。在 PSO 中，粒子的速度决定算法的收敛速度与局部收敛能力，因此许多文献都对 PSO 进行了改进，如对算法的速度项引入了惯性权重以平衡搜索的全局性和收敛速度、设计不同类型的拓扑结构来改变粒子的学习模式等^[7-8]。

本文为了避免 PSO 陷入局部最优，融合了柯西变异的思想，对当前种群中的最优粒子施加干扰，使其自适应地产生变异，有助于提升算法的局部寻优能力；为了加快算法的收敛速度，引入梯度指导交叉思想，使粒子在下降速度最快的负梯度方向上进行一维搜索，最终形成了自适应柯西变异和梯度指导交叉粒子群(Cauchy Mutation and Gradient Guidance Cross Particle Swarm Optimization, GMGPSO)算法。将该算法与电厂的实测数据相结合进行负荷系统建模，得到了最优模型参数。仿真结果表明本文算法改善了基本粒子群算法的辨识精度与收敛速度，得到的负荷系统模型精度较高。

1 自适应柯西变异和梯度指导交叉粒子群算法

1.1 自适应柯西变异粒子群

柯西-洛伦兹分布是一个期望和方差均不存在的连续型分布函数^[9]，其概率密度函数为：

$$f(x) = \frac{1}{\pi} \frac{\gamma}{(x^2 + \gamma^2)} \quad (1)$$

式中： γ 为最大值一半处的一半宽度尺寸参数。

当 $\gamma=1$ 时，标准柯西分布的概率密度函数为：

$$f(x) = \frac{1}{\pi(x^2 + 1)} \quad (2)$$

粒子群算法经过一次次的迭代之后，算法在结果相近的几个候选粒子之间振荡，此时算法产生搜索停滞从而导致过早收敛。因此，可以在此时对陷入局部最优的粒子施加微小干扰，即进行变异操作，让粒子自适应地产生变异。

假设种群的个体数为 N ，每个个体的维数为 Dim 。由此计算每个个体各维度的平均值为

$$Avg(i) = \frac{\sum_{j=1}^N X_{bi}[j][i]}{N} \quad (3)$$

式中： i 为个体维度编号， $i=1,2,\dots,Dim$ ； j 为个体编号， $j=1,2,\dots,N$ ； $X_{bi}[j][i]$ 为空间中第 j 个粒子在第 i 维上的矢量模值。

计算最优个体与平均值之间的各维度间距

$$d(i) = X_{bg}(i) - Avg(i) \quad (4)$$

式中： X_{bg} 为种群中的最优个体。

上述求得的各维度距离反映了种群的离散分布程度，得到改进的柯西分布函数为

$$F(i) = \frac{1}{\pi} \arctan \left\{ \left[1 - \frac{d(i)}{d_{\max}} \right] e^{-\lambda_g / g_{\max}} \right\} + \frac{1}{2} \quad (5)$$

式中： d_{\max} 为各维度距离的最大值； g_{\max} 为最大迭代次数； λ_g 为缩放因子。

根据 PSO 算法的位置、速度理论，新个体的位置由老个体的位置与当前的速度决定，故可采用式(6)对最优个体进行变异操作得到新个体

$$X_{bg}^*(i) = X_{bg}(i) + \frac{\sum_{j=1}^N v[j][i]}{N} \cdot F(i) \quad (6)$$

式中： $v[j][i]$ 为第 j 个粒子在第 i 维上的速度矢量模值。

1.2 自适应梯度指导交叉粒子群

根据文献[10]，若梯度 $grad f(x_k)=0$ ，则优化问题存在局部最优解。因此，若存在 ε ，使得梯度向量模值 $\|grad f(x_k)\| > \varepsilon$ ，则点 x_k 不是要寻找的局部最优点。此时，为了加快算法的收敛速度，可以沿着 x_k 处的负梯度方向进行一维搜索，以便找到更好的个体。梯度指导交叉原理如图 1 所示。




图 1 梯度指导交叉示意图

Fig. 1 Schematic of gradient guidance crossover

图 1 中 x_k 为当前的最优个体, 其负梯度方向为 x_k 与 x^* 的连线, 指向 x^* 。 x_1 和 x_2 为沿着负梯度方向, 角度在 α 内的两点, 也就是能进行梯度指导交叉的个体。

由于粒子的分布特性, 并不能保证当代粒子中恰好有粒子位于最优点的负梯度方向上, 所以采用范围搜索的策略, 在最优点的负梯度方向上确定角度范围(在图 1 中为角度 α), 选择该范围内的个体, 在梯度指导策略下进行交叉操作。而 α 的大小决定了可以进行交叉的粒子规模, 不同大小的 α 角度将对算法的性能产生如下影响:

(1) 当 α 较小时, 沿负梯度方向 α 角范围内可进行交叉操作的粒子较少, 粒子多样性变差;

(2) 当 α 较大时, 沿负梯度方向 α 角范围内可以进行交叉操作的粒子数量又太多, 反而会影响到算法的收敛速度。

因此, 可采取自适应策略, 使算法在前期具有较强的全局搜索能力, 在后期具有较强的局部搜索能力。在算法初期, 较强的全局搜索能力对应较大的 α 角, 随着迭代进行到后期, 群体中的粒子已经大范围接近到某一最优解附近, 此时算法应具有较强的局部搜索能力, 对应的 α 角较小。

假设第 k 代粒子为 $x_k^1, x_k^2, \dots, x_k^N$, 相对应的适应度值为 $f_k^1, f_k^2, \dots, f_k^N$, 取平均适应度值为

$$f_k = \frac{\sum_{i=1}^N f_k^i}{N} \quad (7)$$

式中: N 为种群的粒子数目。

依据离散程度来自适应改变 α 角的大小为:

$$\alpha = \frac{\pi}{4} \cdot \frac{f_{\max} - f_{\min}}{f_{\max} - f_k} \quad (8)$$

式中: f_{\max} , f_{\min} 分别为种群中最优个体和最次个体对应的适应度值。

为了保证每次迭代之后粒子的适应度值均有所改善, 算法的搜索方向与负梯度方向之间的夹角 β 满足条件:

$$0 \leq \beta \leq \alpha \quad (9)$$

$$0 \leq \alpha \leq \pi/2 \quad (10)$$

式中: α 和 β 如图 1 所示, β 为被选个体 x_i 与当前最优个体 x_k 连线所组成的向量与负梯度方向之间的夹角。

若 $\beta > \alpha$, 则说明被选个体与梯度方向之间的夹角较大, 即该个体不在角 α 范围内, 所以该个体将不与其他个体进行交叉。

根据文献[11], 任意给定的 2 个个体进行算术交叉后所产生的后代个体必定位于 2 个个体之间的连线上。因此, 采用的交叉策略为:

$$x_1' = \lambda_1 x_1 + \lambda_2 x_2 \quad (11)$$

$$x_2' = \lambda_1 x_2 + \lambda_2 x_1 \quad (12)$$

式中: λ_1 和 λ_2 分别为交叉系数; x_1 和 x_2 分别为待交叉个体; x_1' 和 x_2' 为交叉后所得到的个体。

2 负荷系统结构确定及数据预处理

2.1 模型辨识原理

超(超)临界机组负荷系统建模主要包括以下 2 部分的内容: (1) 模型结构的确定。通过分析系统的静态、动态特性等, 选择恰当的模型结构。(2) 确定模型中的待辨识参数。依据算法, 以现场数据作为输入, 得到模型的输出与实际输出相比较, 根据两输出之间的误差多次修改初始参数范围, 得到最优的辨识模型。辨识原理图如图 2 所示。




图2 参数辨识原理图
Fig. 2 Identification schematic

2.2 超超临界机组负荷系统结构确定

负荷系统具有高阶惯性、纯迟延、非线性等特点，其机理较为复杂^[12-13]，故可通过式(13)来描述负荷系统的数学模型：

$$G(s) = \frac{K(1 - \alpha s)e^{-\tau s}}{s^m(Ts + 1)^n} \quad (13)$$

式中： K 为系统增益； α 为积分常数； τ 为迟延时间常数； T 为惯性时间常数； $m=1$ 时系统无自衡； $m=0$ 时系统有自衡； n 为惯性阶次。

通过分析系统的动态特性，选取3个主要输入变量：主调门开度、总燃料量和给水流量；3个主要输出变量：机组功率、中间点温度和主蒸汽压力，得到超(超)临界机组负荷系统的系统结构如图3所示。由于主调门开度对中间点温度的影响、给水流量对机组功率的影响均较小，故不对上述2个回路进行辨识。




图3 1000 MW 超超临界机组负荷系统结构图
Fig. 3 Structure of load system

图3中U为系统输入，Y为系统输出，U1为主调门开度，U2为总燃料量，U3为给水流量，Y1

为机组功率，Y2为中间点温度，Y3为主蒸汽压力。

负荷系统中，同一输出对不同输入的响应特性存在差异。依据热工过程阶跃响应曲线^[14]，可对不同回路的传递函数做一定调整，调整依据如下：

(1) 对于过渡过程较长、响应较慢的回路可以增加惯性环节的数目；

(2) 由于机组功率对主调门开度变化的响应，主蒸汽压力对给水流量的响应速度均较快，因此对于以上2个回路可以引入微分环节。

2.3 数据筛选与处理

火电厂分散控制系统历史数据库中有着大量的历史数据，从中挑选出机组处于稳定工况下的数据为辨识所用。通常情况下，当机组负荷波动小于一定范围时，就可以认定机组处于稳定工况^[15]，稳定工况的判别依据为：

$$\delta_x = (X_{\max} - X_{\min}) / X_a < \varphi \quad (14)$$

式中： X_{\max} 为该段时间内负荷的最大值； X_{\min} 为该段时间内负荷的最小值； X_a 为该段时间内负荷的平均值； φ 为稳定阈值，取0.02。

依据式(14)确定稳定工况后，在稳定工况下选取系统发生扰动后的数据段作为建模数据，由文献[1]可知，其中稳定段的数据主要是用来辨识系统的静态特性，中间的波动段数据用来辨识系统的动态特性。

当采用传递函数来描述对象时，需要对系统的输入输出有一个范围约束。本文选取1000 MW超超临界机组在75%左右运行工况下的数据作为系统的输入输出，并对数据段进行零初始化处理，采用的零初始化策略为

$$\begin{cases} u^*(k) = u(k) - \frac{1}{N} \sum_{i=1}^N u(i) \\ y^*(k) = y(k) - \frac{1}{N} \sum_{i=1}^N y(i) \end{cases} \quad (15)$$

式中： N 为数据的个数； u 为输入； y 为输出。采用对输入输出数据的平均策略，原始数据段会向下平移，平移的大小为各数据的均值。

3 建模实例与分析

负荷系统建模部分主要包括算法性能验证、系统模型训练和模型有效性校验。

3.1 算法性能验证

截取主调门开度——功率回路的数据进行算法性能验证。依次采用粒子群(PSO)、自适应梯度指导粒子群(Gradient Guidance Particle Swarm Optimization, GGPSO)、自适应柯西变异粒子群(GMPSO)和自适应柯西变异及梯度指导交叉粒子群(Gradient Guidance Crossover Particle Swarm Optimization, GMGPSO) 4 种算法对参数进行辨识。所得校验数据的辨识曲线如图 4 所示。

单从曲线上并不能了解辨识的实际效果, 因此将从数据层面进行分析。由于存在偶然性且程序每次运行的结果都不一样, 故采用多次运算取平均值

的方法分别得到表 1~2 所示的训练数据和校验数据的辨识性能结果。为了对比 4 种算法的性能差异, 采用均方误差指标来衡量算法的辨识精度, 通过比较算法的执行时间来衡量算法的收敛速度。

分析表 1~2 可得到结论:

(1) 采用 GGPSO 能有效地提高算法的收敛速度。训练数据耗时从 262.9 s 缩短至 145.6 s, 平均收敛速度提高了 44.6%, 校验数据收敛速度提高了 56%;

(2) 采用 GMPSO 能有效地提高算法的精度。训练数据均方误差较粒子群算法下降 38.4%, 校验数据误差下降 46.6%;

(3) GMGPSO 则综合了 GGPSO 和 GMPSO 两者的优点, 在提高了算法精度的前提下, 还能明显加快算法的收敛速度。




图 4 校验数据 4 种算法辨识结果对比

Fig. 4 Identification comparisons of PSO, GGPSO, GMPSO, and GMGPSO

表1 训练数据辨识性能对比

Tab. 1 Identification performance comparison of training data

算法	均方误差	耗时/s
PSO	4.175	262.9
GGPSO	3.213	145.6
GMPSO	2.570	263.2
GMGPSO	2.878	187.2

表2 校验数据辨识性能

Tab. 2 Identification performance of validating data

算法	均方误差	耗时/s
PSO	2.315	96.12
GGPSO	1.973	42.28
GMPSO	1.237	95.60
GMGPSO	1.229	59.23

3.2 负荷系统模型训练

截取 10~33 000 s 时间段内的数据作为辨识的训练数据。采用 GMGPSO 算法, 设定程序仿真参数为: 粒子种群数目为 150, 算法迭代次数为 200, 变异概率为 0.4, 交叉概率为 0.4。得到的辨识曲线如图 5 所示, 辨识性能参数如表 3 所示。由图 5 可以看出, 模型输出拟合现场实际数据效果较好; 由表 3 可知, 3 个回路的均方误差均较小, 模型训练效果较好。




图5 负荷系统训练数据辨识输出与实际输出结果
Fig. 5 Load system identification result of training data

表3 负荷系统训练数据辨识性能

Tab. 3 Identification performance of training data

参数	均方误差	耗时/s
实际功率	0.368	76.56
中间点温度	0.475	76.56
主蒸汽压力	0.429	76.56

根据多次训练结果得到各回路的传函为:

$$G_{11}(s) = \frac{139.79s}{(47.19s+1)(9.87s+1)} \quad (16)$$

$$G_{13}(s) = \frac{-45.38}{(95.79s+1)(107.31s+1)} \quad (17)$$

$$G_{21}(s) = \frac{5.03}{(28.18s+1)(99.67s+1)(128.75s+1)} \quad (18)$$

$$G_{22}(s) = \frac{1.87}{(32.56s+1)(78.19s+1)(146.37s+1)} \quad (19)$$

$$G_{23}(s) = \frac{0.29}{(110.56s+1)(8.51s+1)} \quad (20)$$

$$G_{32}(s) = \frac{-4.45}{(2.38s+1)(13.63s+1)(17.90s+1)} \quad (21)$$

$$G_{33}(s) = \frac{10.68s}{(42.77s+1)(78.09s+1)(106.32s+1)} \quad (22)$$

3.3 模型验证

为了验证该模型的有效性和适用性, 依据训练得到的各回路传递函数, 选取与训练数据无关的另一时间段运行数据进行模型校验。模型的计算输出与实际校验数据的对比结果如图 6 所示, 图中实际功率与主蒸汽压力的模型输出与实际数据基本吻合, 中间点温度曲线存在微小偏差。与其他建模方法进行性能比较的结果如表 4 所示, 分析可知, GMGPSO 算法建立的模型精度较高, 比基本的粒子群算法建立的模型均方误差小, 且算法收敛速度也有所提升。进一步说明了该方法对于复杂热工对象的适用性。




图 6 负荷系统校验数据辨识输出与实际输出结果
Fig. 6 Load system identification result of validating data

表 4 负荷系统校验数据辨识性能对比
Tab. 4 Identification performance comparison of validating data

算法	参数	均方误差	耗时/s
PSO	实际功率	1.038	30.06
	中间点温度	1.472	30.06
	主蒸汽压力	0.916	30.06
GMGPSO	实际功率	0.204	16.29
	中间点温度	0.328	16.29
	主蒸汽压力	0.165	16.29

4 结论

以某电厂 1 000 MW 超超临界机组历史数据为基础, 依据负荷系统的结构模型, 利用自适应柯西变异和梯度指导交叉粒子群算法对负荷系统进行建模。试验结果表明, GMGPSO 算法有效提升了基本粒子群算法的收敛速度和辨识精度, 并通过校验分析, 验证了模型的有效性和适用性。

参考文献:

- [1] 袁世通. 1 000 MW 超超临界机组建模理论与方法的研究[D]. 北京: 华北电力大学, 2015.
Yuan Shitong. Research on Modeling Theory and Method of 1 000 MW Ultra Supercritical Unit[D]. Beijing: North China Electric Power University, 2015.
- [2] 孙海蓉, 王蕊, 耿军亚. 基于信息熵的 BP 网络在热工系统建模中的应用[J]. 系统仿真学报, 2017, 29(1): 226-233.

- Sun Hairong, Wang Rui, Geng Junya. Thermal System Modeling Based on Entropy and BP Neural Network[J]. Journal of System Simulation, 2017, 29(1): 226-233.
- [3] 黄宝海, 韩璞, 葛忠真, 等. 基于现场数据的电站过热器神经网络建模[J]. 华北电力大学学报(自然科学版), 2008, 35(2): 66-69.
Huang Baohai, Han Pu, Ge Zhongzhen, et al. Modeling a Super-heater of Power Plant Based on Neural Network Using Field Data[J]. Journal of North China Electric Power University (Natural Science Edition), 2008, 35(2): 66-69.
- [4] 刘长良, 于希宁, 姚万业, 等. 基于遗传算法的火电厂热工过程模型辨识[J]. 中国电机工程学报, 2003, 23(3): 170-174.
Liu Changliang, Yu Xining, Yao Wanye, et al. Identification of Thermal Process Model of Thermal Power Plant based on Genetic Algorithm[J]. Proceedings of the Chinese Society for Electrical Engineering, 2003, 23(3): 170-174.
- [5] 李擎, 张超. 一种基于粒子群参数优化的改进蚁群算法[J]. 控制与决策, 2013, 28(6): 873-883.
Li Qing, Zhang Chao. An Improved Ant Colony Algorithm based on Particle Swarm Optimization[J]. Control and Decision, 2013, 28(6): 873-883.
- [6] 苟小龙, 张杰, 王家胜, 等. 基于粒子群算法的汽轮机及其调速系统参数辨识方法[J]. 系统仿真学报, 2014, 26(7): 1511-1516.
Gou Xiaolong, Zhang Jie, Wang Jiasheng, et al. Parameter Identification Method of Steam Turbine and Its Speed Governor System Based on Particle Swarm Optimization[J]. Journal of System Simulation, 2014, 26(7): 1511-1516.
- [7] Shi Y H, Eberhart R. A Modified Particle Swarm Optimizer[C]//Conference on Evolutionary Computation. Anchorage: IEEE, 1998: 69-73.
- [8] Kennedy J. Bare Bones Particle Swarms[C]//Swarm Intelligence Symposium. Indianapolis: IEEE, 2003: 80-87.
- [9] 康岚兰, 董文永, 田降森. 一种自适应柯西变异的反向学习粒子群优化算法[J]. 计算机科学, 2015, 42(10): 226-231.
Kang Lanlan, Dong Wenyong, Tian Jiagsen. A Reverse Learning Particle Swarm Optimization Algorithm based on Adaptive Cauchy Variation[J]. Computer Science, 2015, 42(10): 226-231.
- [10] 梁昔明, 龙文, 龙祖强, 等. 自适应梯度指导交叉的进化算法[J]. 小型微型计算机系统, 2011, 32(7):

- 1331-1335.
- Liang Ximing, Long Wen, Long Zuqiang, et al. Adaptive Gradient Guidance Crossover Evolutionary Algorithm[J]. Journal of Chinese Mini-Micro Computer Systems, 2011, 32(7): 1331-1335.
- [11] Gen M, Cheng R W. Geneticalgorithm and Engineering Design[M]. NewYork: JohnWiley, 1997: 379-381.
- [12] 常敬涛. 改进的最小二乘算法在热工对象模型辨识中的研究及应用[D]. 保定: 华北电力大学, 2010.
- Chang Jingtao. Research and Application of Improved Least Squares Algorithm in Thermal Object Model Identification[D]. Baoding: North China Electric Power University, 2010.
- [13] 张微微, 张会生, 苏明. 混烧高炉煤气的火电机组热力系统建模与仿真分析[J]. 热力发电, 2012, 41(4): 59-64.
- Zhang Weiwei, Zhang Huisheng, Su Ming. Modeling and Simulation Analysis of Thermal System of Thermal Power Unit with Mixed Blast Furnace Gas[J]. Thermal Power Generation, 2012, 41(4): 59-64.
- [14] 韩璞, 袁世通. 基于大数据和双量子粒子群算法的多变量系统辨识[J]. 中国电机工程学报, 2014, 34(32): 5779-5787.
- Han Pu, Yuan Shitong. Multivariable System Identification Based on Double Quantum Particle Swarm Optimization and Big Data[J]. Proceedings of the Chinese Society for Electrical Engineering, 2014, 34(32): 5779-5787.
- [15] 张法文. 热工过程控制系统分析、设计和调试[M]. 北京: 中国电力出版社, 1997.
- Zhang Fawen. Analysis, Design and Commissioning of Thermal Process Control Systems[M]. Beijing: Electric Power Press, 1997.