

利用极值蚁群优化的制粉出力建模变量选择算法

贾立新, 郑伊飞, 曹晖

(西安交通大学电力设备电气绝缘国家重点实验室, 710049, 西安)

摘要: 针对制粉出力难以直接测量, 以及制粉系统包含变量多且各变量间耦合性强的问题, 提出了一种利用极值蚁群优化的制粉出力建模变量选择法, 并采用支持向量机根据所选变量建立了制粉出力的预测模型. 该算法基于蚁群优化的正反馈原理, 对蚂蚁搜索到的各个变量的相对重要性加以区分, 并根据幂律分布选择重要性较小的变量进行变异, 使得较差解不断得到改善, 从而引导蚂蚁朝着最优解的方向搜索. 采用制粉系统现场数据对所提算法、蚁群算法和蚁群遗传算法进行比较, 结果表明, 所提算法具有更快的收敛速度, 且由其所选变量建立的制粉出力模型具有较高的预测精度.

关键词: 制粉系统; 制粉出力; 变量选择; 极值蚁群优化

中图分类号: TP18 **文献标志码:** A **文章编号:** 0253-987X(2011)10-0007-06

Variable Selection Method Based on Extreme Ant Colony Optimization for Pulverizing Capability Model

JIA Lixin, ZHENG Yifei, CAO Hui

(State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Since the pulverizing capability is unable to be measured directly and there exist numerous strongly-coupling variables in a ball mill pulverizing system, a variable selection method based on extreme ant colony optimization (EACO) for pulverizing capability model is proposed. According to the selected variables, the model is established by support vector regression. On the basis of the positive feedback mechanism of ant colony optimization (ACO), the proposed method is able to identify the relative importance of variables selected by ants, and then mutate unimportant variables following the power law distribution, thus the poor solutions in each iteration process get improved. Consequently, the ants are led to search for the optimal solutions. The proposed algorithm is compared with ACO and ant colony optimization with genetic algorithm on the field data of ball mill pulverizing system. The experiment results show the higher convergence rate and prediction accuracy.

Keywords: ball mill pulverizing system; pulverizing capability; variable selection; extremal ant colony optimization

制粉系统是火电厂的主要辅助系统之一, 其耗电量约占厂用电量的 1/4. 在我国煤炭和电力能源短缺的严峻形势下, 使制粉系统工作在最优工况, 即制粉出力最大, 是火电厂实现节能降耗的重要途径^[1]. 因此, 制粉出力的准确测量是实现整个系统优

化控制的前提.

制粉系统是一个非线性、多变量、强耦合的对象, 通过测量单一信号表征制粉出力具有局限性^[2]. 文献[2-4]提出了制粉出力的软测量方法, 而进行软测量建模的首要问题是输入变量的选择. 变量选择

过多,则可能引入无关变量或冗余变量,不仅使模型变得复杂,还会降低预测精度;变量选择过少,则不能全面反映影响制粉出力的信息,同样也会增大预测误差. 蚁群算法(ACO)是模拟蚂蚁群体智能行为的启发式算法,已经成功用于解决一些复杂的组合优化问题^[5]. 变量选择属于组合优化范畴,文献[6-7]利用蚁群算法进行了变量选择,文献[8-9]提出了蚁群算法与遗传算法融合的变量选择算法.但是,以上算法都是基于蚂蚁的随机搜索,并未考虑每个变量的相对重要性,因此其中包含了大量的重复搜索,造成收敛速度较慢且容易陷入局部最优解.

本文提出了一种利用极值蚁群优化(EACO)的制粉出力建模变量选择算法,基于蚁群算法正反馈原理,对蚂蚁搜索到的各个变量的相对重要性加以区分,并根据幂律定律对重要性较小的变量进行变异,使得较差解不断得到改善,从而引导蚂蚁朝着最优解的方向搜索.

1 制粉系统概述

制粉系统承担着火电厂煤粉的磨制、干燥和输送任务,其工艺流程如图 1 所示. 给煤机将原煤送入球磨机内,同时送入的还有热风、冷风和再循环风. 原煤经过破碎研磨,磨好的煤粉被气流送出,经粗粉分离器后,不合格的煤粉通过循环通道返回球磨机继续研磨,合格的煤粉被带入细粉分离器进行气粉分离,再次合格的煤粉落入煤粉仓. 根据锅炉负荷的需要,排粉机将煤粉仓中的煤粉输入一次风管,再送入炉内燃烧.




图 1 制粉过程工艺流程图

制粉出力是指在保证一定煤粉细度的条件下球磨机单位时间内磨制的原煤量,由于制粉系统中变量多且各变量间耦合性强,所以进行变量选择成为制粉出力建模中的首要问题. 制粉系统中可测量的变量主要有 12 个,即磨机负荷、入口负压、出口负压、出入口差压、入口温度、出口温度、粗粉出口负

压、细粉出口负压、排粉出口风压、磨机电机电流、排粉机电流、通风量.

2 基于极值蚁群优化的变量选择方法

制粉出力建模的变量选择可以看作是一个离散组合优化问题,其目的是从以上 12 个变量中选出 d ($d \leq 12$) 个作为输入变量进行建模,并使模型的预测精度最高.

本文借鉴极值优化^[10]思想,提出了一种基于极值蚁群优化(EACO)的制粉出力建模变量选择方法. 该算法先让所有蚂蚁根据信息素浓度构建路径,然后从中选出适应度最好的 s 个解,每个解中选中的变量即为该解的组元. 由于蚂蚁搜索的随机性,这些解中可能仍然包含一些无关变量,也可能漏掉一些重要变量,因而我们对每个解中组元的相对重要性加以区分,根据幂律分布按概率选出重要性较小的组元进行变异,并对得到的新解进行适应度评价,若适应度好于原来的,则用它取代原来的解,否则原解不变. 如此经过 N_m 次变异后,进行信息素更新,从而完成一次迭代过程. 当迭代次数达到指定的最大值时,算法结束. 算法流程如图 2 所示.




图 2 极值蚁群优化流程图

2.1 编码

变量选择可以看成是蚂蚁觅食中寻找最优路径

的过程,每个变量有两种状态 0 或 1(0 代表该变量未被选中,1 代表被选中),每个状态相当于蚂蚁觅食时要经过的节点.针对制粉系统 12 个变量的选择即变为 12 级决策问题,所以用 12 位二进制数表示搜索得到的解.

2.2 信息素存放方式及初始化

每个变量的每种状态都对应一个信息素浓度 τ_{uv} ,其中 u 代表变量序号, v 代表两种状态 0 和 1. 初始信息素浓度均设为 1.

2.3 转移规则

对每个变量而言,蚂蚁选 0 或选 1 的概率如下

$$P_{uv} = \begin{cases} 1, & \text{if } q < q_0 \text{ \& } v = \arg \max(\tau_{u0}, \tau_{u1}) \\ 0, & \text{if } q < q_0 \text{ \& } v \neq \arg \max(\tau_{u0}, \tau_{u1}) \\ \tau_{uv} / (\tau_{u0} + \tau_{u1}), & \text{if } q \geq q_0 \end{cases} \quad (1)$$

式中: P_{uv} 代表变量 u 选中状态 v 的概率; $\arg \max(\tau_{u0}, \tau_{u1})$ 代表 τ_{u0} 和 τ_{u1} 中的最大值所对应的状态; q 是 $[0, 1]$ 区间均匀分布的随机数; q_0 是开发概率因子,其大小决定了利用先验知识与探索新解之间的相对重要性.

2.4 建模方法及适应度评价

每只蚂蚁完成一次搜索后要对所构建的解进行适应度评价.本文选用 ϵ -支持向量机(ϵ -SVR)^[11] 进行建模,其中用径向基(RBF)核作为核函数,通过网络搜索获得影响模型性能的主要参数惩罚因子 c 和 RBF 核参数 g . 10 折交叉验证法训练模型得到的平均均方误差($\bar{\epsilon}_{\text{mse}}$)可以用来表征模型的预测精度,故适应度函数取为 $F = \bar{\epsilon}_{\text{mse}}$, F 值越小,则建模精度越高,其适应度越好.

2.5 极值优化方式

本文采用灰关联分析^[12] 中的关联度作为相对重要性评价指标,对每个组元按关联度从小到大进行排列,其中关联度最小的组元排序等级为 1,关联度最大的组元排序等级为 q . 对于排序等级为 k 的组元,其被选中的概率为 $P(k) = k^{-\lambda} (1 \leq k \leq n, \lambda > 0)$. 也就是说,组元重要性越小,被选中的概率越大.将所选组元从解中剔除,从未进入解的变量中随机选取一个加入解空间,若其适应度好于原来的,则用它取代原来的解,否则原解不变.

2.6 信息素更新方式

本文借鉴最大-最小蚂蚁系统的信息素更新方式,选用每次迭代最优蚂蚁进行信息素更新,同时为加速收敛,每隔 5 次用全局最优蚂蚁进行信息素更新.更新规则如下

$$\tau_{uv}(g_0 + 1) = \rho \tau_{uv}(g_0) + Q / (F_{\text{best}} + \alpha d / n) \quad (2)$$

式中: $\tau_{uv}(g_0)$ 为迭代 g_0 次的信息素浓度; $\rho \in [0, 1]$ 为信息素保留系数,表征信息素挥发的快慢程度; Q 为信息素更新强度; F_{best} 为迭代最优或全局最优的适应度函数值; d 为所选变量数; n 为所有变量数(本文中 $n=12$); d/n 为变量压缩率; α 为权重系数.可见,适应度函数越小,所选变量越少,则信息素增量越大.为防止搜索进入停滞状态,设置信息素的最大值 τ_{max} 与最小值 τ_{min} ,使 $\tau_{uv} \in [\tau_{\text{min}}, \tau_{\text{max}}]$.

3 实验结果及分析


为了对本文所提方法进行验证,通过在某火电厂现场实验,取得制粉系统不同运行工况下的两个数据集.数据集 1 中包含 48 个样本,随机选取 33 组作为训练样本,15 组作为测试样本.数据集 2 中包含 300 个样本,随机选取 200 组作为训练样本,100 组作为测试样本.训练样本和测试样本均包含制粉系统从低负荷运行到高负荷运行的数据.

3.1 极值蚁群优化关键参数设置


本节讨论了影响极值蚁群优化的 5 个关键参数:蚂蚁数、信息素更新强度、幂律分布参数 λ 、参与变异的解的数目及最大变异次数,并对每个参数不同取值下的算法性能进行测试,结果如图 3 所示.由图 3a 可知,蚂蚁数较多可以提高算法的全局搜索能力及算法的稳定性,但数目过多会增加运行时间,因此蚂蚁数的最佳值为 8.信息素更新强度 Q 直接影响蚂蚁在一次信息素更新过程中释放的信息素的量.由图 3b 可知, Q 越大,在较优路径上的信息素累积越快,有助于算法的快速收敛,但 Q 过大造成某一路径上信息素增加过快,容易进入停滞状态, Q 的最佳取值为 0.004.参数 λ 对算法性能也有重要影响,当 $\lambda \rightarrow \infty$ 时,适应度最差的组元发生变异的概率最大,其他适应度的组元发生变异的概率接近于 0,变异过程变成了确定性局部搜索.当 $\lambda \rightarrow 0$ 时,所有组元发生变异的概率都相同,变异过程变成了完全随机搜索.由图 3c 可知, λ 在 1.4 附近可以得到最优解.参与变异的解的数目 s 及最大变异次数 N_m 同样对算法能否收敛到最优解有直接影响.由图 3d 和图 3e 可知, s 和 N_m 取值越大,则搜索空间越大,越有利于搜索到最优解,但运行时间加长,其最佳值分别为 $s=3, N_m=3$.

3.2 测试结果及讨论


本文将 EACO 与文献[6]中的 ACO 算法、文献




(a) 蚂蚁数目




(b) 信息素更新强度



(c) 幂律分布参数



(d) 最大变异次数



(e) 参与变异的解的个数

图 3 极值蚁群优化参数选择

[8]中的 ACO-GA 算法进行比较. 3 种算法的蚂蚁数均为 8,最大迭代次数为 40,信息素更新强度为 0.004,开发概率因子为 0.2,信息素保留系数为 0.9. 对于 EACO 算法, $\lambda=1.4$,参与变异的解的数目取为 3,最大变异次数取为 3. 对于 ACO-GA 算法,交叉概率取为 0.9,变异概率取为 0.1. 分别运行 3 种算法,将其所选变量作为制粉出力模型的输入,利用训练样本对 ϵ -支持向量机所建的制粉出力模型进行训练. 训练完成后得到模型的回归函数,然后分别对训练样本和测试样本进行预测. 预测精度用均方误差(ϵ_{mse})、相对误差(ϵ_{re})和决定系数(R^2)进行评价,其定义如下

$$\epsilon_{mse} = (\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2)^{1/2}$$

$$\epsilon_{re} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

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

式中: N 为样本个数; y_i 为制粉出力实测值; $\bar{y}_i$ 为制粉出力实测值的平均值; $\hat{y}_i$ 为模型预测值; $\bar{\hat{y}}$ 为模型预测值的平均值. R^2 越接近于 1, ϵ_{mse} 和 ϵ_{re} 越接近于 0,则模型预测值与制粉出力实测值越吻合,建模精度越高. 3 种算法在数据集 1 上的测试结果如表 1 所示,迭代最优适应度函数值的变化曲线如图 4 所示. 在数据集 2 上的测试结果如表 2 所示,迭代最优适应度函数值的变化曲线如图 5 所示. 3 种算法达到收敛所需时间如表 3 所示. 从表 1 和表 2 均可看出,用 3 种变量选择算法所选变量进行建模,所得模型的预测精度均优于用所有变量进行建模的精度. 对数据集 1 来说,用 EACO 算法进行变量选择后的建模精度分别比 ACO-GA 和 ACO 算法得到的建模精度高出 33%和 63%;EACO 算法的收敛速度分




图 4 在数据集 1 上测试所得的迭代最优适应度函数值变化曲线

表 1 3 种算法在数据集 1 上的测试结果

算法	变量数	训练集			测试集		
		ϵ_{mse}	ϵ_{re}	R^2	ϵ_{mse}	ϵ_{re}	R^2
未经变量选择	12	0.009 546	0.013 110	0.991 4	0.016 920	0.023 240	0.889 0
ACO	7	0.004 643	0.005 308	0.992 7	0.006 947	0.005 618	0.923 8
ACO-GA	5	0.002 113	0.002 726	0.994 1	0.003 826	0.003 435	0.963 3
EACO	5	0.001 395	0.001 542	0.995 4	0.002 531	0.001 708	0.985 8

表 2 3 种算法在数据集 2 上的测试结果

算法	变量数	训练集			测试集		
		ϵ_{mse}	ϵ_{re}	R^2	ϵ_{mse}	ϵ_{re}	R^2
经变量选择	12	1.334×10^{-4}	1.214×10^{-2}	0.976 8	1.818×10^{-4}	1.924×10^{-2}	0.949 2
ACO	7	9.585×10^{-5}	6.276×10^{-3}	0.998 7	1.245×10^{-4}	8.218×10^{-3}	0.956 1
ACO-GA	5	8.463×10^{-5}	4.639×10^{-3}	0.999 1	9.142×10^{-5}	6.414×10^{-3}	0.973 6
EACO	5	6.735×10^{-5}	1.266×10^{-3}	0.999 7	7.678×10^{-5}	1.554×10^{-3}	0.999 6

别比 ACO-GA 算法和 ACO 算法高出 30%和 43%。对数据集 2 来说,用 EACO 算法进行变量选择后的建模精度分别比 ACO-GA 算法和 ACO 算法的算法得到的建模精度高出 16%和 38%;EACO 算法的收敛速度分别比 ACO-GA 算法和 ACO 算法高出 16%和 17%。

区分,并根据幂律定律对重要性较小的变量进行变异,使得较差解不断得到改善,从而引导蚂蚁朝着最优解的方向搜索.实验结果表明,本文所提方法具有更快的收敛速度,用其所选变量建立的模型具有更高的预测精度.该方法不仅为制粉系统的优化控制打下了良好的基础,而且具有较强的工程实用价值。




图 5 在数据集 2 上测试所得的迭代最优适应度函数值变化曲线

表 3 3 种算法达到收敛所需时间

数据	收敛时间/s		
	EACO	ACO-GA	ACO
数据集 1	19.6	28.2	34.5
数据集 2	136.2	158.7	164.5

4 结 论

本文提出了一种利用极值蚁群优化的制粉出力建模变量选择算法.该算法基于蚁群算法的正反馈原理,对蚂蚁搜索到的各个变量的相对重要性加以

参考文献:

[1] 刘定平,肖蔚然,陆继东. 中间储仓式制粉系统调整的优化研究[J]. 华北电力大学学报, 2007, 34(3): 55-59.
LIU Dingping,XIAO Weiran,LU Jidong. Research on optimizing for adjustment of storage pulverizing system [J]. Journal of North China Electric Power University,2007,34(3): 55-59.

[2] 程启明,王勇浩. 火电厂中间仓储式球磨机制粉系统控制技术发展综述[J]. 上海电力学院学报, 2006, 22(1): 48-54.
CHENG Qiming,WANG Yonghao. The overview on the development of control techniques on intermediate storage bunker ball mill pulverizing system of power plant[J]. Journal of Shanghai University of Electric Power, 2006, 22(1): 48-54.

[3] WANG Heng, JIA Mingping, HUANG Peng, et al. A study on a new algorithm to optimize ball mill system based on modeling and GA[J]. Energy Conversion and Management, 2010, 51(4): 846-860.

[4] 苏志刚,王培红,于向军,等. 中储式制粉系统出力在线监测软测量建模[J]. 中国电机工程学报, 2007, 27(29): 90-99.

- SU Zhigang, WANG Peihong, YU Xiangjun, et al. Soft sensor modeling for on-line monitoring the capacity of coal pulverizing system[J]. Proceedings of the CSEE, 2007, 27(29): 90-99.
- [5] DORIGO M, STÜTZLE T. Ant colony optimization [M]. Cambridge, MA, USA: MIT Press, 2004: 25-63.
- [6] MOHAMMAD G, MATHEUS P F, RICHARD J. Ant colony optimization as a feature selection method in the QSAR modeling of anti-HIV-1 activities of 3-(3, 5-dimethylbenzyl) uracil derivatives using MLR, PLS and SVM regressions[J]. Chemometrics and Intelligent Laboratory Systems, 2009, 98(2): 123-129.
- [7] SHAHLA N, MOHAMMAD B. Text-independent speaker verification using ant colony optimization-based selected features[J]. Expert Systems with Applications, 2011, 38(1): 620-630.
- [8] MOHAMMAD E B, SHAHLA N. A novel hybrid ACO-GA algorithm for text feature selection[C] // Proceedings of IEEE Congress on Evolutionary Computation. Piscataway, NJ, USA: IEEE, 2009: 2561-2568.
- [9] NEMATİ S, BASIRI M, AGHAEI N, et al. A novel ACO-GA hybrid algorithm for feature selection in protein function prediction [J]. Expert Systems with Application, 2009, 36(10): 12086-12094.
- [10] BOETTCHER S, PERCUS A G. Optimization with extremal dynamics[J]. Complexity, 2003, 8(2): 57-62.
- [11] 冯瑞,宋春林,张艳珠,等. 基于支持向量机与RBF神经网络的软测量模型比较研究[J]. 上海交通大学学报, 2003, 37(S1): 122-125.
FENG Rui, SONG Chunlin, ZHANG Yanzhu, et al. Comparative study of soft sensor models based on support vector machines and RBF neural networks [J]. Journal of Shanghai Jiaotong University, 2003, 37(S1): 122-125.
- [12] 陈朱娟,陈绍炳. 基于一种新的灰关联系数表达式的磨煤出力关联分析[J]. 发电设备, 2009, 23(6): 393-396.
CHEN Zhujuan, CHEN Shaobing. Coal mill capacity analysis based on a new expression of gray relation coefficient [J]. Power Equipment, 2009, 23(6): 393-396.

(编辑 杜秀杰)