

炼焦生产过程综合生产指标的改进神经网络预测方法

王 伟, 吴 敏, 雷 琪, 曹卫华

(中南大学 信息科学与工程学院, 湖南 长沙 410083)

摘要: 针对炼焦生产过程综合生产指标(焦炭质量、产量和焦炉能耗)检测的严重滞后问题, 提出一种改进BP神经网络预测方法. 首先基于相关过程参数的主元分析和灰色关联分析, 确定出预测模型的输入输出变量; 然后采用基于改进差分进化算法的BP神经网络建立预测模型, 并与基本BP神经网络预测模型进行比较; 最后, 对改进BP神经网络预测模型进行了验证. 实验结果表明, 改进BP神经网络预测模型具有较快的收敛速度和较高的预测精度, 模型的预测效果可以满足生产工艺要求.

关键词: 炼焦生产过程; 主元分析; 灰色关联分析; 改进差分进化算法; 改进BP神经网络; 预测模型

中图分类号: TP273 **文献标识码:** A

An improved neural network method for the prediction of comprehensive production indices in coking process

WANG Wei, WU Min, LEI Qi, CAO Wei-hua

(School of Information Science and Engineering, Central South University, Changsha Hunan 410083, China)

Abstract: A prediction method based on the improved back propagation(BP) neural network is proposed to solve the problem of large time-delay in the detection of the comprehensive production indices (quality and quantity of coke, and energy consumption of coke oven) in the coking process. First, the input and output variables of the prediction models are determined by analyzing the process mechanism correlation between process parameters based on principal components analysis and grey relational analysis. Then, the BP neural network based on an improved differential evolution algorithm is applied to establish prediction models, which are compared with the basic BP neural network prediction models. Finally, the prediction models are verified. Simulation results show that the proposed prediction models provide a better convergence rate and higher prediction accuracy, and the prediction effect of the obtained models satisfy the technological requirements.

Key words: coking process; principal component analysis; grey relational analysis; improved differential evolution algorithm; improved BP neural network; prediction model

1 引言(Introduction)

炼焦生产过程是一个复杂的物理化学反应过程, 实际工艺中涉及到多个过程, 如焦炉加热燃烧过程、焦炉煤气集气过程、装煤过程、推焦—拦焦—熄焦过程和综合回收过程等, 具有强非线性、大时滞等特点. 炼焦生产过程的综合生产目标是在焦炉稳顺运行和焦炭质量满足要求的前提下, 使焦炭产量最大, 焦炉能耗最小, 从而提高企业的竞争力, 实现可持续发展. 因此, 把焦炭质量、产量和焦炉能耗(质量产量能耗)作为炼焦生产过程的综合生产指标. 受现有检测设备、检测水平等因素的制约, 质量产量能耗均为8h检测一次, 存在严重滞后, 操作人员很难对其进行实时客观评价, 因而影响到综合生产目标的实现. 由于炼焦生产过程具有一定关联性, 采用传

统机理建模方法建立质量产量能耗模型具有很大困难, 因此迫切需要研究新技术建立工业实用的质量产量能耗预测模型, 为实现炼焦生产过程的优化控制奠定基础.

神经网络方法不需要建立对象的机理数学模型, 又能合理描述对象的特征, 具有并行处理、学习能力强、鲁棒性好等特点, 因此在复杂系统的预测建模中得到了广泛的应用. 例如, 采用神经网络取代机理建模中的部分变化参数或难以描述的非线性部分, 也有通过引入专家规则并用组合的方法进行建模, 这些方法取得了明显的控制效果^[1~4]. 基于此, 文献[5,6]采用变学习率的BP神经网络建立质量产量能耗预测模型, 但该BP神经网络的训练基于误差函数梯度下降算法, 用于描述具有复杂工况特征的

炼焦生产过程时,在目标点附近收敛速度慢、效率低,并且许多学习问题中适应度函数在解空间内是不可微或是不连续的,使得后续优化控制目标函数的建立受到很大制约。

为克服BP神经网络的上述不足,将差分进化算法引入到神经网络的训练中。差分进化(differential evolution, DE)算法是一种新兴的基于群体智能的进化计算技术^[7]。它通过群体内个体间的合作与竞争产生的群体智能指导优化搜索,它采用实数编码、基于差分的简单变异操作和一对一的竞争生存策略,降低了遗传操作的复杂性,它特有的记忆能力使其具有较强的全局收敛能力和鲁棒性,适于求解一些利用常规的数学规划方法无法求解的复杂优化问题。近年来,DE算法正受到日益关注,其应用邻域也越来越广^[8~11]。

预测模型作为后续优化控制的基础,模型精度对于保证优化的有效性、可靠性具有重要的意义。本文以炼焦生产过程为例,提出一种基于改进差分进化算法的BP神经网络综合生产指标预测方法。首先对原料参数进行主元分析,并将分析结果和过程参数一起进行灰色关联分析,从而确定预测模型的输入输出变量;然后采用基于改进差分进化算法的神经网络方法,建立质量产量能耗预测模型,并从神经网络训练速度和模型精度两方面与基本BP算法进行比较;最后对基于改进差分进化算法的预测模型进行了验证,证明本文方法的有效性。

2 炼焦工艺过程(Coking technological process)

2.1 机理分析(Mechanism analysis)

现代焦炉炉体最上部是炉顶,炉顶之下为相间配置的燃烧室和炭化室,炉体下部有蓄热室和连接蓄热室与燃烧室的斜道区。焦炉型号较多,本文所涉及的某钢铁企业焦炉为JN-60型焦炉。在炼焦生产过程中,煤料从煤塔卸到煤车分别送至各炭化室装炉,再将一定量的煤气和适当比例的空气经蓄热室预热后,送至燃烧室混合燃烧,煤在炭化室内由两侧燃烧室经硅砖壁传热进行单向供热干馏。炭化室内的煤在干馏过程中产生大量的荒煤气,荒煤气通过集气管流往冷凝器进行净化与重利用。整个结焦周期一般为18.5h~23h,然后由推焦机把焦炭推出,并用惰性气体进行干熄焦。

在炼焦生产过程综合生产指标中,焦炭质量指标包括其水分、挥发分、灰分、硫分、抗碎强度、耐磨强度;焦炭产量指标按照通常标准以t/8h来衡量;由于炼焦生产中所用的煤气有高炉煤气、焦炉煤气以及两者混合煤气,故焦炉能耗指标以高炉煤气消耗

量和焦炉煤气消耗量来衡量。

2.2 预测模型输入输出变量的确定 (Determination for the input and output variables of prediction models)

以焦炭质量预测模型为例,基于炼焦生产的机理分析以及实际经验,初步确定影响焦炭质量的因素包括:配合煤质量,火道温度,集气管压力,结焦时间,烟道吸力。其中配合煤质量指标包括粘结性指数、挥发分、硫分、灰分、水分、细度、胶质层指数、胶质层厚度,由于其包含的指标众多,从简化建模复杂性的角度出发,采用主元分析方法^[5,12]对其进行降维处理,最终得到配合煤质量第1,2,3,4主成分。

由于质量预测模型的影响因素较多,只依靠机理分析和现场操作人员经验的定性分析结果来确定主要影响因素,可靠性不高,并且缺乏理论依据。因此,在机理分析和现场经验定性分析的基础上,采用灰色关联分析方法^[5,13]从定量分析的角度确定各因素对预测模型的影响程度。分析得到配合煤质量第1,2,3,4主成分 $x_1 \sim x_4$,机侧火道温度 x_5 ,焦侧火道温度 x_6 ,集气管压力 x_7 ,结焦时间 x_8 对焦炭质量影响较大,将它们作为焦炭质量预测模型的输入变量;输出变量为焦炭的水分 Y_{11} ,挥发分 Y_{12} ,灰分 Y_{13} ,硫分 Y_{14} ,抗碎强度 Y_{15} ,耐磨强度 Y_{16} 。

采用相似方法对焦炭产量、焦炉能耗预测模型进行分析,得到焦炭产量预测模型输入变量为:机侧火道温度 x_5 ,焦侧火道温度 x_6 ,集气管压力 x_7 ,结焦时间 x_8 ,每孔装煤量 x_9 ,出炉数 x_{10} ;输出变量为:焦炭产量 Y_2 。焦炉能耗预测模型输入变量为:机侧火道温度 x_5 ,焦侧火道温度 x_6 ,集气管压力 x_7 ,结焦时间 x_8 ,机侧高炉煤气流量 x_{11} ,焦侧高炉煤气流量 x_{12} ,机侧高炉煤气压力 x_{13} ,焦侧高炉煤气压力 x_{14} ,机侧混合煤气流量 x_{15} ,焦侧混合煤气流量 x_{16} ,机侧烟道吸力 x_{17} ,焦侧烟道吸力 x_{18} ;输出变量为:高炉煤气消耗量 Y_{31} 和焦炉煤气消耗量 Y_{32} 。

3 改进BP神经网络预测模型(Improved BP neural network prediction models)

为克服基本BP算法的不足,本文采用改进差分进化算法来训练BP神经网络预测模型,以提高模型的预测精度和收敛速度;同时,为减小网络训练的复杂性,采用3层的网络结构,来建立质量产量能耗预测模型。

3.1 焦炭质量预测模型(Coke quality prediction model)

以焦炭质量预测为例,确定神经网络预测模型的输入变量为8个: $x_1 \sim x_8$,输出变量为6个: $Y_{11} \sim Y_{16}$ 。

根据Kolmogorov定理和实际调试分析将隐层节点数设为 20. 隐层神经元传递函数采用 S 型正切函数 $\tan \operatorname{sig}$, 输出层神经元传递函数采用线性函数 $\operatorname{purelin}$. 焦炭质量神经网络预测模型可以用公式(1)表示:

$$Y_{1k} = \sum_{i=1}^{20} w_{k,i} \tan \operatorname{sig} \left(\sum_{j=1}^8 w_{i,j} x_j + b_i \right) + \theta_k. \quad (1)$$

式中: $w_{i,j}$ 为第 j 个输入变量到第 i 个隐层神经元的权值, b_i 为对应第 i 个隐层神经元的阈值, $w_{k,i}$ 为第 i 个隐层神经元到第 k 个输出变量的权值, θ_k 为对应第 k 个输出神经元的阈值, $\tan \operatorname{sig}(\cdot)$ 表示非线性 sigmoid 激励函数.

采用非线性函数 $f_{\text{JZ}}(\cdot)$ 表示 3 层 BP 神经网络描述的焦炭质量输入输出间的非线性关系, 其预测模型可以描述为

$$Y_{1i} = f_{\text{JZ}}(x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8), \quad (2)$$

其中 $i = 1, 2, \dots, 6$.

3.2 焦炭产量、焦炉能耗预测模型(Coke quantity and energy consumption prediction models)

焦炭产量、焦炉能耗和原料参数、过程参数间也存在一定关联度, 因此采用类似神经网络方法对焦炭产量、焦炉能耗分别建立预测模型. 模型采用相同的 3 层 BP 神经网络结构, 隐层结点数分别为 15 和 27. 用非线性函数 $f_{\text{JC}}(\cdot)$ 和 $f_{\text{JN}}(\cdot)$ 分别表示 3 层 BP 神经网络描述的焦炭产量、焦炉能耗输入输出间的非线性关系, 则其预测模型可以描述为:

焦炭产量神经网络预测模型:

$$Y_2 = f_{\text{JC}}(x_5, x_6, x_7, x_8, x_9, x_{10}). \quad (3)$$

焦炉能耗神经网络预测模型:

$$Y_{3i} = f_{\text{JN}}(x_5, x_6, x_7, x_8, x_{11}, x_{12}, x_{13}, x_{14}, x_{15}, x_{16}, x_{17}, x_{18}). \quad (4)$$

其中 $i = 1, 2$.

3.3 改进差分进化算法(An improved differential evolution algorithm)

差分进化算法的基本思想是: 对当前种群进行变异和交叉操作, 产生一个新种群; 然后利用基于贪婪思想的选择操作对这两个种群进行一对一的选择, 从而产生新一代种群. 具体而言, 对于初始种群 $X^0 = [x_1^0 \ x_2^0 \ \dots \ x_{N_p}^0]$, 个体 $x_i^0 = [x_{i1}^0 \ x_{i2}^0 \ \dots \ x_{iD}^0]$ 表征问题的一个解. 首先通过式(5)对每一个在 t 时刻的个体 x_i^t 实施变异操作, 得到与其相对应的变异个体 u_i^{t+1} , 即

$$u_i^{t+1} = x_{r1}^t + F(x_{r2}^t - x_{r3}^t), \quad (5)$$

其中: $r1, r2, r3 \in (1, 2, \dots, N_p)$ 互不相同且与 i 不同, x_{r1}^t 为父代基向量, $x_{r2}^t - x_{r3}^t$ 为父代差分向量, F 为范围在 $[0, 2]$ 之间的变异算子. 然后利用式(6)对生成的变异个体 u_i^{t+1} 实施交叉操作, 生成试验个体 x_i^{t+1} , 即

$$x_{ij}^{t+1} = \begin{cases} u_{ij}^{t+1}, & \text{rand}(j) \leq CR \text{ 或者 } j = \text{rnbr}(i), \\ x_{ij}^t, & \text{其他}, \end{cases} \quad j \in (1, 2, \dots, D), \quad (6)$$

其中: $\text{rand}(j)$ 为 $[0, 1]$ 之间均匀分布的随机数, CR 为范围在 $[0, 1]$ 之间的交叉算子, $\text{rnbr}(i)$ 为 $(1, 2, \dots, D)$ 中的随机整数.

利用式(7)对试验个体 u_i^{t+1} 和 x_i^t 的目标函数进行比较, 对于最小化问题, 则选择目标函数值低的个体作为新种群的个体 x_i^{t+1} , 即

$$x_i^{t+1} = \begin{cases} u_i^{t+1}, & f(u_i^{t+1}) < f(x_i^t), \\ x_i^t, & \text{其他}, \end{cases} \quad (7)$$

其中 f 为目标函数.

基本 DE 算法子代的生成采用“贪婪”选择方式, 变异个体由 3 个互不相同的随机个体组成, 无需任何适应度函数值的信息, 有利于保持种群的多样性, 因而全局搜索能力强, 但收敛速度慢.

文献[14,15]提供了其余 DE 算法的个体变异模式, 其中 DE/best/2/bin 变异模式如下所示:

$$v_i^{t+1} = x_{\text{best}}^t + F(x_{r1}^t - x_{r2}^t + x_{r3}^t - x_{r4}^t). \quad (8)$$

在该变异方式中, 变异个体 v_i^{t+1} 由当前最优个体 x_{best}^t 作引导, 因而局部搜索能力强, 精度高, 但会加大算法陷入局部最优解的可能. 通过分析可知变异算子 F 越大, $(x_{r1}^t - x_{r2}^t + x_{r3}^t - x_{r4}^t)$ 部分对变异个体 v_i^{t+1} 的贡献越大, 有利于保持种群的多样性; 反之, x_{best}^t 对变异个体 v_i^{t+1} 的贡献越大, 可避免最优解遭到破坏. 同时, 基本 DE 算法中交叉算子 CR 越大, 变异个体 v_i^{t+1} 对试验个体 u_i^{t+1} 的贡献越多, 有利于局部搜索和加速收敛速度; 反之, t 代个体 x_i^t 对试验个体 u_i^{t+1} 的贡献越多, 有利于保持种群的多样性和全局搜索. 因此, 在 DE/best/2/bin 变异方式基础上采用式(7)和(8)所示的自适应变异算子 F 和交叉算子 CR :

$$F = F_{\text{base}} * 2^{e^{\left(1 - \frac{\text{epochs}}{\text{epochs} + 1 - it}\right)}}, \quad (9)$$

$$CR = CR_{\text{min}} + \frac{it(CR_{\text{max}} - CR_{\text{min}})}{\text{epochs}}. \quad (10)$$

式中: F_{base} 是基本变异概率, CR_{min} 是最小交叉概率, CR_{max} 使最大交叉概率, epochs 是最大进化代数, it 是当前进化代数.

3.4 基于改进差分进化算法的神经网络训练(Neural network training based on the improved differential evolution algorithm)

为了对基于改进差分进化算法的质量产量能耗预测模型进行验证,采用批量训练方式,在输入相同数据样本的情况下,分别用基本BP算法和改进差分进化算法进行网络训练.采用MATLAB神经网络工具箱建立BP神经网络,为了加快BP网络的收敛速度,采用梯度下降动量学习函数,其动量常数设置为0.9.改进差分进化算法参数设置如下:变异算子 F_{base} 为0.6,交叉算子 CR_{min} 为0.2, CR_{max} 为0.8,种

群大小设为100.

以某钢铁企业焦化厂的生产历史数据为基础,在[0, 1]范围内初始化神经网络的权值,取经过数据滤波、数据插值等预处理的最近4个月数据,其中最新1个月的数据用于测试,其余3个月数据用于网络训练,训练样本共有270组数据.由于炼焦生产过程的复杂性,现场检测得到的数据波动比较大,为了确保预测模型能获得较优的权值和阈值,训练次数设为2500.

表1~3分别表示焦炭质量、产量和焦炉能耗神经网络的训练结果.

表1 焦炭质量的两种模型预测结果
Table 1 Results of quality prediction model

算法	训练 时间/min	水分的 相对误差/(%)	挥发分的 相对误差/(%)	灰分的 相对误差/(%)	硫分的 相对误差/(%)	抗碎强度的 相对误差/(%)	耐磨强度的 相对误差/(%)
基本BPNN模型	31	8.2	7.4	3.8	4.7	3.7	4.9
改进BPNN模型	25	4.5	3.8	1.9	2.6	1.5	2.7

表2 焦炭产量的两种模型预测结果
Table 2 Results of quantity prediction model

算法	训练时间/min	相对误差/(%)
基本BPNN模型	20	4.7
改进BPNN模型	16	2.9

表3 焦炉能耗的两种模型预测结果
Table 3 Results of energy consumption prediction model

算法	训练 时间/min	高炉煤气消 耗相对误差/(%)	焦炉煤气消 耗相对误差/(%)
基本BPNN模型	24	4.3	3.5
改进BPNN模型	21	2.7	1.6

通过上述预测结果可知,与基本BP神经网络预测模型相比,基于改进差分进化算法的BP神经网络预测模型在训练时间和精度上都有明显提高.在模型的训练中,由于选取了距当前时刻最近的3个月数据作为训练样本,能比较好的反映最近一个时期炼焦生产的不同工况,预测模型经离线训

练投入运行后,不需要经常重新训练,只要根据当前统计的焦炉生产过程相关参数,通过预测模型计算出质量产量能耗指标,其时间代价为几秒钟.

实际炼焦生产过程处在不断变化之中,为使预测模型能随系统运行保持较高的预测精度,预测模型需要随着过程的变化进行自学习.现场数据样本每8h检测一次,将经过数据滤波、数据插值等预处理的最新样本加入到自学习库文件中替换掉最早的样本,当样本库中新数据累积到一定数量时,采用后台训练方式对已经建立的预测模型进行修正,但数据样本的累积周期比较长,一般为半个月时间,并且在每炉焦炭18.5h~23h的一个生产周期内,有足够时间对预测模型进行修正.因此,25 min, 21 min, 16 min的模型训练时间是可以接受的,算法效率可以满足实际炼焦生产的需要.

4 预测模型的验证(Verification for the prediction models)

为检验模型的有效性,将最新1个月的93组数据作为测试集,分别对质量产量能耗预测模型进行验证,其预测和分析结果如表4和图1~3所示.

表4 焦炭质量、产量和焦炉能耗指标的相对误差平均值
Table 4 Average relative errors of the quality-quantity-energy consumption indices

预测指标	水分	挥发分	灰分	硫分	抗碎强度	耐磨强度	焦炭产量	高炉煤气消耗量	焦炉煤气消耗量
相对误差平均值/(%)	6.14	5.05	2.69	3.49	2.21	3.53	4.89	4.44	2.32




图 1 焦炭质量指标的仿真效果

Fig. 1 Simulation results of coke quality indexes




图 2 焦炉能耗指标的仿真效果

Fig. 2 Simulation results of coke-oven energy consumption indexes




图 3 焦炭产量指标的仿真效果

Fig. 3 Simulation result of coke quantity indexes

炼焦生产过程是一个复杂的物理、化学反应

过程, 其控制还远没有达到精细控制的程度, 从图1~3可以得出, 质量产量能耗预测模型对各指标的预测值与实际值变化趋势基本一致, 从表4可知各指标的相对误差平均值均较小, 模型具有较高的预测精度. 与传统质量产量能耗指标8h检测一次相比, 本文方法能较好的反映出当前炼焦生产过程各指标的基本情况, 对于处于粗放控制的炼焦生产而言更具有现实意义. 考虑到炼焦生产过程中统计的过程参数本身存在很多不确定因素导致的统计误差, 本文获得的预测效果可以满足生产工艺要求, 预测模型具有较高的有效性.

5 结论(Conclusion)

本文以炼焦生产过程综合生产指标建模为研究背景,提出一种基于改进差分进化算法的质量产量能耗BP神经网络预测方法.从模型训练和模型验证结果可以看出,本文建立的预测模型能够准确地反映质量产量能耗指标的变化趋势,并具有较高的预测精度,预测效果可以满足生产工艺要求,较好的解决了炼焦生产过程中综合生产指标建模困难的问题,为解决综合生产指标的优化控制提供了有力的依据,为生产过程提供了有益的参考.

参考文献(References):

- [1] 唐朝晖, 桂卫华, 吴敏, 等. 基于神经网络和灰色理论的密闭鼓风炉透气性预测模型[J]. 中国有色金属学报, 2003, 13(5): 1306 – 1310.
(TANG Zhaohui, GUI Weihua, WU Min, et al. Predication model based on neural network and gray theory for imperial blast furnace breathing capacity[J]. *The Chinese Journal of Nonferrous Metals*, 2003, 13(5): 1306 – 1310.)
- [2] 李劫, 孔玲爽, 阳春华. 氧化铝烧结法生产的生料浆质量预测模型及应用[J]. 中国有色金属学报, 2006, 16(3): 536 – 541.
(LI Jie, KONG Lingshuang, YANG Chunhua. Raw mix slurry quality prediction model used for alumina sintering production process[J]. *The Chinese Journal of Nonferrous Metals*, 2006, 16(3): 536 – 541.)
- [3] 陈泰任, 曹卫华, 吴敏, 等. 一种新的集成模型在焦炉火道温度软测量中的应用[C] //第26届中国控制会议论文集. 北京: 北京航空航天大学出版社, 2007, 3: 282 – 286.
(CHEN Tairan, CAO Weihua, WU Min, et al. A new integrated model and its application to soft-sensing of the flue temperature in coke oven[C] //*Proceedings of the 26th Chinese Control Conference*. Beijing: Beijing Aeronautical and Astronautical University Press, 2007, 3: 282 – 286.)
- [4] 喻寿益, 王吉林, 彭晓波. 基于神经网络的铜闪速熔炼过程工艺参数预测模型[J]. 中南大学学报(自然科学版), 2007, 38(3): 523 – 527.
(YU Shouyi, WANG Jilin, PENG Xiaobo. Prediction model of craft parameters based on neural network during the processs of copper flash smelting[J]. *Journal of Central South University(Science and Technology)*, 2007, 38(3): 523 – 527.)
- [5] 王伟, 吴敏, 雷琪, 等. 炼焦生产过程质量产量能耗的集成优化控制[J]. 化工学报, 2008, 59(7): 1749–1754.
(WANG Wei, WU Min, LEI Qi, et al. Integrated optimal control of coke quality, coke yield and energy consumption for coking process[J]. *Journal of Chemical Industry and Engineering(China)*, 2008, 59(7): 1749 – 1754.)
- [6] 赖旭芝, 李爱萍, 吴敏, 等. 基于多目标遗传算法的炼焦生产过程优化控制[J]. 计算机集成制造系统, 2009, 15(5): 990–997.
(LAI Xuzhi, LI Aiping, WU Min, et al. Optimization control based on the multi-objective genetic algorithm for coking plant production processs[J]. *Computer Integrated Manufacturing Systems*, 2009, 15(5): 990 – 997.)
- [7] STORN R, PRICE K. Differential evolution-a simple and efficient adaptive scheme for global optimization over continuous spaces, TR-95-012[R]. Berkeley: International Computer Science Institute, 1995.
- [8] AYDIN S, TEMELTAS H. Fuzzy-differential evolution algorithm for planning time-optimal trajectories of a unicycle mobile robot on a pre-defined path[J]. *Advanced Robotics*, 2004, 18(7): 725 – 748.
- [9] KAPADI M D, GUDI R D. Optimal control of fed-batch fermentation involving multiple feeds using differential evolution[J]. *Process Biochemistry*, 2004, 39(11): 1709 – 1721.
- [10] CHANG Y P, WU C J. Optimal multiobjective planning of large-scale passive harmonic filters using hybrid differential evolution method considering parameter and loading uncertainty[J]. *IEEE Transactions on Power Delivery*, 2005, 20(1): 408 – 416.
- [11] 王亮红, 王耀南, 周少武, 等. 双群体伪并行差分进化算法研究及应用[J]. 控制理论与应用, 2007, 24(3): 453 – 458.
(WU Lianghong, WANG Yaonan, ZHOU Shaowu, et al. Research and application of pseudo parallel differential evolution algorithm with dual subpopulations[J]. *Control Theory & Applications*, 2007, 24(3): 453 – 458.)
- [12] 李允公, 张金萍, 吴宁祥, 等. 基于主元分析的频谱整体识别方法[J]. 东北大学学报(自然科学版), 2008, 29(9): 1322 – 1325.
(LI Yungong, ZHANG Jinping, WU Ningxiang, et al. A PCA-based integrative spectrum identification method[J]. *Journal of Northeastern University(Natural Science)*, 2008, 29(9): 1322 – 1325.)
- [13] KUO Y, YANG T, HUANG G W. The use of grey relational analysis in solving multiple attribute decision-making problems[J]. *Computers & Industrial Engineering*, 2008, 55(1): 80 – 93.
- [14] RAINER S, PRICE K. Differential evolution-a simple and efficient heuristic for global optimization over continuous spaces[J]. *Journal of Global Optimization*, 1997, 11(4): 341 – 359.
- [15] 周艳平, 顾幸生. 差分进化算法研究进展[J]. 化工自动化及仪表, 2007, 34(3): 1 – 5.
(ZHOU Yanping, GU Xingsheng. Development of differential evolution algorithm[J]. *Control and Instruments in Chemical Industry*, 2007, 34(3): 1 – 5.)

作者简介:

王 伟 (1982—), 男, 博士研究生, 目前研究方向是复杂工业过程建模与优化控制, E-mail: riguai@163.com;

吴 敏 (1963—), 男, 博士, 长江学者特聘教授, 博士生导师, 目前研究方向是过程控制、鲁棒控制和智能系统, E-mail: min@csu.edu.cn;

雷 琪 (1974—), 女, 博士, 讲师, 目前研究方向为过程控制和智能控制, E-mail: leiqi@mail.csu.edu.cn;

曹卫华 (1972—), 男, 博士, 副教授, 目前研究方向是过程控制、智能控制和机器人技术, E-mail: caowh@mail.csu.edu.cn.