第 32 卷第 5 期
2015 年 5 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 32 No. 5
May 2015

DOI: 10.7641/CTA.2015.13075

竖炉焙烧过程的智能设定模型

严爱军[1,2,3†], 黄晓倩[1,2,4]

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124; 2. 数字社区教育部工程研究中心, 北京 100124;

3. 计算智能与智能系统北京市重点实验室, 北京 100124; 4. 城市轨道交通北京实验室, 北京100124)

摘要: 为了改善多目标评价案例推理设定模型在竖炉焙烧过程控制中的性能, 运用注水原理分配过程变量的权重和群决策修正方法对多目标评价案例推理设定方法进行改进, 得到一种新的智能设定模型. 首先引入注水原理构造Lagrange函数对过程变量的权重进行优化分配, 再通过案例检索和案例重用得到设定值的建议解, 并根据多目标评价模型预测建议解对生产指标的影响效果, 最后, 对不合理的设定值进行群决策修正. 将得到的设定模型应用于竖炉焙烧过程控制中, 通过实验测试和对比应用说明了本文方法优于其他方法, 能够有效提高多目标评价案例推理设定模型的控制性能.

关键词: 竖炉; 智能设定; 多目标评价; 案例推理; 群决策

中图分类号: TP273　　**文献标识码**: A

Intelligent setting model for shaft furnace roasting process

YAN Ai-jun[1,2,3†], HUANG Xiao-qian[1,2,4]

(1. College of Electronic Information and Control Engineering, Beijing University of Technology, Beijing 100124, China;
2. Engineering Research Center of Digital Community, Ministry of Education, Beijing 100124, China;
3. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China;
4. Beijing Laboratory for Urban Mass Transit, Beijing 100124, China)

Abstract: To improve the control performance of the setting model with multi-objective evaluation and case-based reasoning (MOE & CBR) for shaft furnace roasting process, we make use of the water-filling based weight allocation (WFA) to allocate weights for process variables and employ the group decision-marking revision (GDMR) to develop a new intelligent setting method. First, a Lagrange function is constructed to optimize the allocation of the weights of the process variables via WFA. Subsequently, the suggested solutions of set-points are obtained through case retrieval and case reuse. These suggested solutions are used to evaluate the production performance indices based on the multi-objective evaluation (MOE) model. Those unreasonable set-points from MOE model are revised by GDMR. The proposed method has been applied to the shaft furnace roasting process. The application results indicate that the proposed method is superior to other methods and it can significantly improve the control performance of MOE & CBR model.

Key words: shaft furnace; intelligent setting; multi-objective evaluation (MOE); case-based reasoning (CBR); group decision-making (GDM)

1 引言(Introduction)

竖炉焙烧是选矿过程的一个重要子过程, 焙烧过程所使用的原料比较常见的有球团矿和赤铁矿两种, 其中, 赤铁矿竖炉焙烧是为了改善对弱磁性赤铁矿矿石的分选效果, 采用竖炉预先对矿石进行高温还原磁化焙烧, 使弱磁性矿物变成强磁性矿物的一个过程[1]. 对于该过程的优化控制来说, 已经证明, 单纯的回路稳定控制难以实现产品质量、产量、能耗等生产指标的优化控制, 还须对影响生产指标的关键被控变量进行合理的设定[2]. 由于竖炉焙烧过程的机理复杂, 呈现出多变量、非线性和强耦合特征, 建立精确的机理设定模型比较困难[3]. 于是, 关于该过程设定建模的研究就显得尤为重要[4].

对涉及到影响生产指标的关键被控变量的设定问题, 实质上就是针对输入(当前的工况信息及过程数据)和输出(被控变量的期望值)建立设定模型的问题. 从设定方法及建模的研究现状来看, 一般需从实际对象的特点出发, 考虑诸多内因及外因, 然后采用合适的建模方法. 不论采用何种方法, 最核心的问题还是如何保证设定值的合理性, 即所谓的优化问题. 由于优化设定技术的重要性, 许多专家学者在设定方法及

收稿日期: 2013−05−17; 录用日期: 2015−02−27.
†通信作者. E-mail: yanaijun@bjut.edu.cn; Tel.: +86 10-67396376 .
国家自然科学基金项目(61374143), 北京市自然科学基金项目(4152010)资助.
Supported by National Natural Science Foundation of China (61374143) and the Beijing Natural Science Foundation of China (4152010).

应用方面进行了大量的研究工作[5–9]. 其中, 基于机理模型的设定方法取得了不同程度的应用成效, 但对难以获得精确数学模型的过程建模来说, 还须寻求其他方法. 借助于人工智能技术来实现优化设定任务是该领域的一个研究热点[10]. 例如, 将机理模型和专家模型结合, 并辅之以动态校正等手段保证设定值的优化[11]. 然而, 典型的智能技术比如人工神经网络或专家规则存在训练样本或专家规则难以获取的问题, 这限制了其进一步的应用. 由于案例推理(case-based reasoning, CBR)方法可以避免这些缺陷[12], 利用发生过的经验案例进行推理得到设定值的过程相对容易, 并显示出应用潜力, 因而得到了广泛关注[2–4].

针对竖炉焙烧过程关键被控变量的优化设定问题, 由于其机理模型难以建立, 为了实现变量的自动设定并改进传统CBR设定模型的准确率, 本文将注水原理(water-filling theory, WFT)和群决策(group decision-making, GDM)思想引入到案例推理过程, 在对过程变量的权重进行注水法分配(water-filling based weight allocation, WFA)和设定值的合理性进行多目标评价(multi-objectiv e evaluation, MOE)的基础上, 实现设定值的GDM修正(group decision-marking revision, GDMR). 通过竖炉焙烧过程的工业应用例子, 检验了本文得到的权重WFA分配法和修正设定值的GDMR方法的有效性, 与竖炉焙烧过程现有设定方法的对比结果说明了该方法具有应用优势.

2 过程控制描述(Process control description)

赤铁矿竖炉焙烧过程的主要目的是将进入竖炉的弱磁性铁矿石加热至1100°C左右, 然后在一定温度下(570°C左右)与CO或H_2发生还原反应, 从而变成强磁性铁矿物. 该过程一般可划分为4个子过程, 即给矿、燃烧加热、还原反应和冷却搬出, 如图1所示.

通过竖炉焙烧工艺过程的机理分析, 关键被控变量主要有燃烧室温度、还原煤气流量和搬出时间, 实现它们的稳定控制对焙烧矿的质量、产量、能耗等生产指标的优化控制有着重要意义. 但是单纯的回路稳定控制并不能满足生产需求, 还须对燃烧室温度、还原煤气流量和搬出时间进行合理的设定. 由于各回路的设定值与众多输入变量的关系是一个结构参数未知的多变量非线性过程, 难以建立准确的机理模型, 可用下面的时变函数描述[2]:

$$\begin{cases} y_1(k+1) = f_1(x_1(k), x_2(k), \cdots, x_7(k); | \\ \qquad\qquad y_2(k), y_3(k)), \\ y_2(k+1) = f_2(x_1(k), x_5(k), x_6(k); | \\ \qquad\qquad y_1(k), y_3(k)), \\ y_3(k+1) = f_3(x_1(k); y_1(k), y_2(k)), \end{cases} \tag{1}$$

其中: 输出变量y_1–y_3分别表示燃烧室温度、还原煤气流量和搬出时间的设定值; 输入变量x_1–x_7分别表示还原带温度、加热煤气量、加热空气量、加热煤气压力、炉膛负压、还原煤气压力和加热煤气热值. 从式(1)可以看出输出变量互相耦合, 合理的设定值很难通过机理计算的方法得到, 所以, 必须寻求先进的优化设定方法来实现.

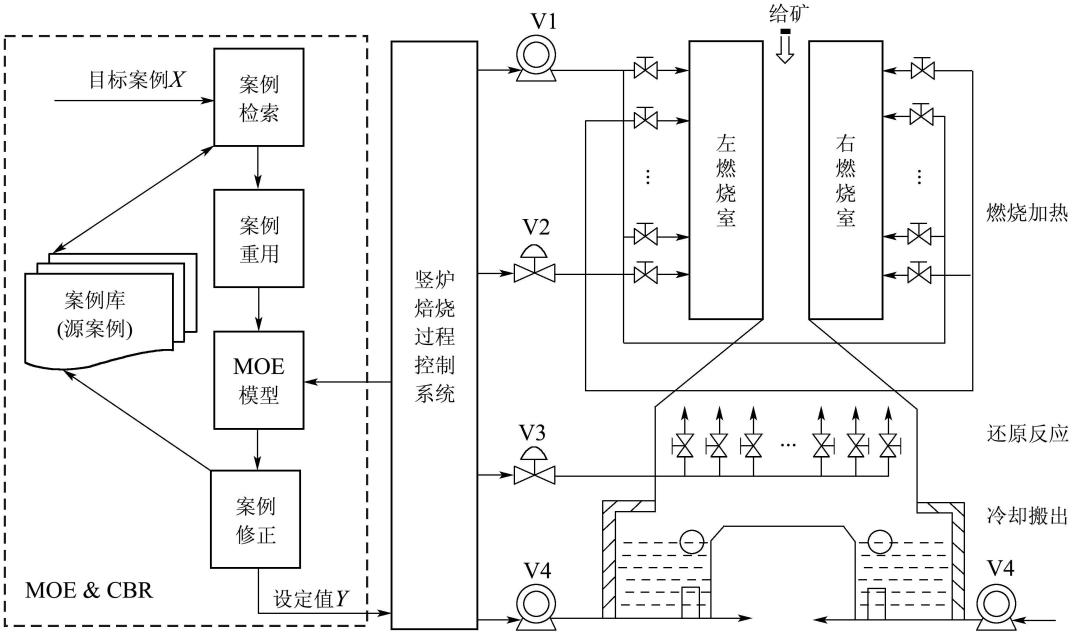

图 1 竖炉焙烧过程及MOE&CBR设定模型

Fig. 1 Technical process of shaft furnace roasting with MOE&CBR setting mode

由于CBR方法基于人的认知心理, 无需建立对象准确的机理模型, 通过输入输出变量的特征值就可以推理得到关键被控变量的设定值, 这些优点使得它在具有综合复杂性的竖炉焙烧过程的设定建模中已取得应用成效. 图1虚框部分给出了求取设定值Y的MOE&CBR设定模型[2]的结构原理, 其中的案例检索环节通过计算待求解的目标案例X与案例库中源案例的相似度, 从中寻找最相似案例, 重用设定解并经过MOE模型的评价, 如果生产指标的控制效果不理想则通过基于规则的案例修正(rule-based case revision, RBR)来对设定值进行调整, 经过调整后的设定值送入竖炉焙烧过程控制系统参与控制, 同时作为新的案例存储于案例库中, 供下次的设定求解. 该模型存在的主要问题有: 一是推理模型中过程变量的权重由领域专家给出, 带有一定的主观性; 二是RBR方法的规则难以获取. 这些问题的存在, 使求解精度达不到要求, 因此, 限制了CBR方法在设定建模中的进一步使用, 必须对现有的设定模型进行改进, 以提高其推理性能.

3　智能设定模型(Intelligent setting model)

本节首先给出了智能设定模型的结构与功能, 然后对设定模型的算法实现进行了描述, 包括案例检索、WFA模型、MOE模型和GDMR模型的具体实现方法.

3.1　结构与功能(Structure and functions)

在图1所示MOE评价模型的框架下, 采用WFT方法分配过程变量的权重, 得到分配权重的WFA模型, 并将GDM思想用于案例解的修正过程, 从而得到一种新的智能设定模型, 如图2所示. 由WFA模型、案例检索、MOE模型和GDMR模型等部分组成. 这种新的设定策略沿用了文献[2]设定模型中的MOE评价功能, 可以对生产指标的控制效果进行事前预测, 以评价设定值的合理性, 改进之处在于: 采用客观计算的WFA方法替换了以前依靠领域专家主观确定权重的方法, 而且在修正环节中嵌入GDM思想, 可以避免RBR方法难以获取修正规则的缺陷. 具体的设定功能如下所述.

案例库中存储的是过去设定的实例, 即源案例, 当式(1)中的过程变量x_1–x_7组成的目标案例X输入至模型后, 需要给出式(1)中设定值$Y=(y_1,y_2,y_3)$. 通过案例检索和重用得到设定值的建议解, 利用MOE模型对设定值的使用效果进行预测与评价后, 一般有两种结果出现: 一是效果理想则直接使用; 更为常见的是效果并不理想, 此时不宜直接使用, 需对建议解适当调整和修改, 即经过GDMR模型修正后进入过程控制系统使用, 最后, 将当前状态X下的设定值Y存储于案例库中, 用于下一次的设定求解.

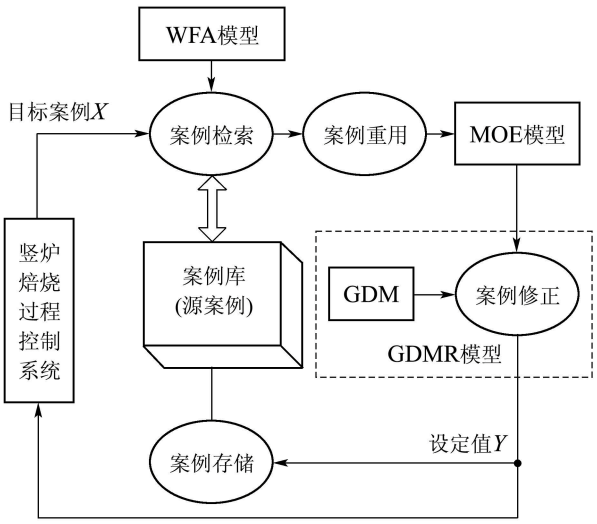

图 2　智能设定模型的结构

Fig. 2　Framework of intelligent setting model

3.2　算法实现(Implementation of the algorithm)

根据图2所示的模型结构及功能, 下面给出案例检索、WFA模型、MOE模型、GDMR模型等关键环节的实现算法.

3.2.1　案例检索(Case retrieval)

从CBR的求解过程来看, 首先要将案例库中的源案例用适当的方法进行表示, 即所谓的案例表示, 它是推理求解的基础. 从竖炉焙烧过程采集到的过程变量x_1–x_7均为连续变化的实参数, 采用特征值描述法表达该过程的设定案例. 将每条源案例C_k $(k=1,2,\cdots,p)$表示为如下的二元组形式:

$$C_k:\langle X_k;Y_k\rangle,\ k=1,2,\cdots,p, \tag{2}$$

其中: p是案例总数; X_k和Y_k分别是源案例的问题描述(这里称过程变量集)和源案例的解答(这里称被控变量的设定值), 可分别表示为

$$X_k=(x_{1,k},x_{2,k},\cdots,x_{7,k}), \tag{3}$$

$$Y_k=(y_{1,k},y_{2,k},y_{3,k}). \tag{4}$$

根据“相似问题具有相似解”的认知假设, 检索阶段模仿了人类的回忆和类比推理思想: 将新的过程参量集, 即目标案例X与源案例的问题描述X_k进行对比, 找到相同或相似度高的问题描述, 相应于X_k的结果Y_k就是检索出的建议解. 下式为计算目标案例X与每一条源案例X_k的相似度:

$$s_k=1-\sqrt{\sum_{i=1}^{7}\omega_i(x_i-x_{i,k})^2}, \tag{5}$$

其中ω_i是第i个输入变量的权重, 表示各变量在设定过程中对设定结果的贡献度大小. 从式(5)可见, X与X_k的相似度计算结果受两方面因素的影响, 一是X与X_k中各属性值的距离, 值越接近, 说明X与X_k越相似, 这一点为定值计算, 无需调整; 二是各变量的权重分配情况会影响X与X_k的相似性. 权重的不同组合对相似结果会产生不同影响. 下文将详细讨论权重的分配问题.

3.2.2 WFA模型(WFA model)

采用WFT原理[13], 将信道功率的优化分配机制应用于案例属性权重的分配中, 提出一种基于WFT的权重分配方法(WFA). 权重分配是否合理由下式决定:

$$R=\sum_{i=1}^{7}\log_2(1+\alpha_i^2\omega_i), \tag{6}$$

式中: R为权重分配的合理性指标(对应于WFT中信道功率分配的容量最大化指标); α_i表示第i个变量的重要程度(对应于WFT中信噪比的高低), 即案例库中第i个变量与被设定变量的相关程度, 可通过计算其相关系数来确定. 权重的约束条件为

$$\begin{cases}\sum\limits_{i=1}^{7}\omega_i=1,\\ \omega_i\geqslant 0.\end{cases} \tag{7}$$

为了合理分配权重, 按WFT的求解思路构造Lagrange函数[13]. 将式(6)和式(7)结合起来, 得到如下的Lagrange函数:

$$L(\omega,\lambda)=\sum_{i=1}^{7}\log_2(1+\alpha_i^2\omega_i)+\lambda(1-\sum_{i=1}^{7}\omega_i), \tag{8}$$

其中λ是Lagrange算子. 式(8)表示满足式(7)的约束条件时, 求得的权重满足式(6)的合理性指标R. 对第i个输入变量的权重求偏导后得到

$$\frac{\partial L}{\partial\omega_i}=\frac{1}{\ln 2}\frac{\alpha_i^2}{(1+\alpha_i^2\omega_i)}-\lambda=0, \tag{9}$$

可解得各变量所分配到的权重, 考虑到式(7)中的约束条件, 权重计算公式为

$$\omega_i=[\varepsilon-\frac{1}{\alpha_i^2}]^+, \tag{10}$$

其中: $[Z]^+$表示0和Z的最大值; ε为门限值, 根据式(7)中的约束条件, 用下式确定其大小:

$$\varepsilon=\frac{1+\sum\limits_{i=1}^{7}\frac{1}{\alpha_i}}{7}. \tag{11}$$

式(10)表明, 权重的分配受变量的重要程度影响, 它对应的α_i^2大, 分配到的权重就大. 由此, 得到了满足式(6)和式(7)的权重分配合理化的算法.

3.2.3 MOE模型(MOE model)

根据图2所示新的设定模型的结构, 引入MOE模型[2], 实现焙烧矿质量、产量及能耗等生产指标的预测. 若这些指标满足生产的要求, 则说明设定值是合理的, 由此建立一种设定值合理性的事前评价机制.

由于反映煤气消耗量的能耗指标与加热煤气、还原煤气的消耗量直接相关, 同时会受到燃烧室温度和还原煤气流量设定值的影响; 焙烧矿质量则受燃烧室温度、还原煤气流量和搬出时间设定值的影响; 产量预测模型相对简单, 主要受搬出时间的影响. 由此列写出下面的关系表达式:

$$\begin{cases}I_1=f_4(x_2,x_6;y_1,y_2),\\ I_2=f_5(y_1,y_2,y_3),\\ I_3=f_6(y_3),\end{cases} \tag{12}$$

其中: I_1– I_3分别表示煤气消耗、产品质量以及产量的预测值; 其他符号的意义参见式(1)说明. 具体算法可参见文献[2]的介绍.

通过式(12), 可以掌握未来生产指标的实现情况, 若指标值比较理想, 说明设定值是合理的, 反之, 则需要修正这些设定值.

3.2.4 GDMR模型(GDMR model)

从认知科学的角度看, 修正环节体现出人类所具备的逻辑思维与创造性思维. 由于案例修正是CBR系统中较难实现的一个步骤, 已经成为案例推理系统设计中的一个研究热点和难点问题[14]. 对建议解进行修正的方法目前一般是根据相关的领域知识和用户的具体要求来进行修正, 还没有通用性的案例修正方法. 本文从问题求解的客观性出发, 引入GDM理论[15]对案例修正环节进行设计.

在案例检索环节, 按式(5)计算出p个相似度后, 通用的做法是设定一个相似度的阈值$\mathrm{sim_v}\in(0,1]$, 假设p个相似度中大于$\mathrm{sim_v}$的案例个数为m, 重新标记这些案例的相似度分别为s_1–s_m, 相应的设定结果共m组, 分别为Y_1–Y_m, 可表示为

$$\begin{cases}Y_j=(y_{1,j},y_{2,j},y_{3,j}),\\ \text{s.t. } s_j\geqslant \mathrm{sim_v},\end{cases}\quad j=1,2,\cdots,m. \tag{13}$$

借鉴GDM思想, 将上述的m组设定结果视为m个决策专家, 期望设定结果为$Y'=(y_1',y_2',y_3')$, m

组设定结果的总误差是

$$E=\sum_{j=1}^{m}\sum_{i=1}^{3}|y_{i,j}-y_i'|. \tag{14}$$

由此计算每一组设定结果的可信度, 定义可信度为

$$\lambda_j=\frac{\sum\limits_{i=1}^{3}|y_{i,j}-y_i'|}{E}, \tag{15}$$

λ_j越大, 表示第j组结果的误差越小, 可信度就高. 从GDM角度来说, 表示该决策专家的权威性越大. 利用群基数效用函数的构造思想, 可以通过每一组设定结果的可信度对目标案例的设定建议解进行GDM修正:

$$y_i=\frac{1}{m}\sum_{j=1}^{m}\lambda_j y_{i,j},\ i=1,2,3. \tag{16}$$

基于上述, 即可实现关键被控变量设定值建议解的修正.

4　工业应用(An industrial application)

为了验证本文方法的有效性和实用性. 将根据上述算法编制的设定程序在某选矿厂竖炉焙烧过程进行了实验测试和对比应用研究. 竖炉焙烧过程控制系统的软硬件平台仍然为文献[2]中介绍的系统. 为了让设定程序投入运行, 需要事先完成过程参量的初始化、案例库的构成、过程变量的权重确定、相似度的阈值选择等.

首先对过程变量集中的各变量进行初始化, 即归一化处理, 将每个变量的特征值都被映射到[0, 1]区间; 其次构建设定案例库, 按照式(2)所示的案例表达方式组成案例库. 根据长期的生产实践, 总结了用于设定的一些源案例, 共180条记录, 将其存储于案例库中. 案例库中的第1条源案例是这样构成的: 式(3)所示的问题描述是(0.2345, 0.3258, $\cdots$, 0.1950), 式(4)所示相应的设定解是(1089, 567, 6.5), 其他源案例的建立过程与此类似; 最后根据式(8)–(11)中各变量的权重依次定为(0.27, 0.16, 0.11, 0.08, 0.07, 0.06, 0.25), 并设相似度的阈值$\mathrm{sim_v}=0.9$.

4.1　有效性测试(Efficiency test)

着重考察新的设定模型能否根据过程变量的状态变化自动计算控制回路的设定值. 观察过程变量在60 s内的变化情况(采样周期为1 s), 还原带温度x_1、加热煤气量x_2和加热煤气热值x_7的实时变化情况如图3所示(其他过程参量处于动态稳定之中, 为观察清晰, 省略其曲线). 图中: 还原带温度x_1呈缓慢下降趋势; 加热煤气量x_2和煤气热值x_7均呈增加态势. 按焙烧工艺要求, 需对控制参数进行调整, 否则会影响焙烧矿的质量.

设定程序运行后, 可得到燃烧室温度y_1、还原煤气流量y_2和搬出时间y_3的新设定值, 如图4所示(纵坐标零刻度分别对应y_1, y_2和y_3的初值). 可以看出, 燃烧室温度y_1的设定值维持不变, 还原煤气流量y_2的设定值增加约2.5%, 搬出时间y_3的设定值减少近10%. 做出这种调整符合焙烧工艺机理的要求: 当还原带温度x_1下降时, 一般要求搬出时间y_3的设定值减少, 并增加还原煤气流量y_2的设定值, 这样可以保证焙烧矿的充分还原, 使得质量指标保持稳定. 燃烧室温度y_1的设定值维持不变的原因是, 当还原带的检测温度x_1下降时, 设定程序已将还原煤气流量y_2的设定值增加, 在这种情况下, 即使不对燃烧室温度y_1的设定值更新也不会影响焙烧矿的质量.

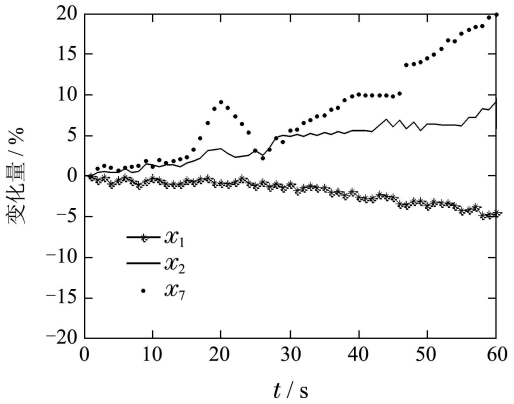

图 3　变量x_1, x_2和x_7的变化趋势

Fig. 3　Trend of variables x_1, x_2 and x_7

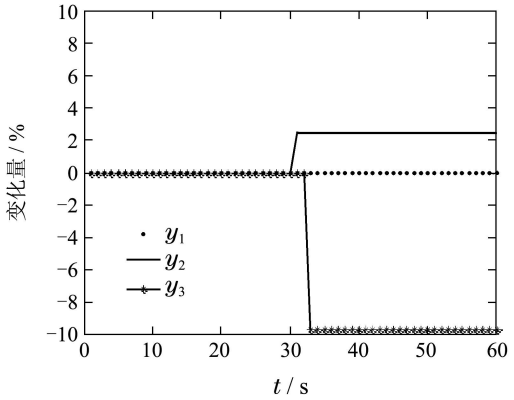

图 4　设定值y_1, y_2和y_3的更新曲线

Fig. 4　Self-adjustment response of set-points y_1, y_2 and y_3

从上述可以看出, 图2所示的设定模型能够对过程变量的变化作出响应, 实现设定值的自动调整, 并且符合焙烧工艺的机理要求, 说明了模型的有效性.

4.2　对比效果分析(Comparative analysis)

设定模型采用传统的均权重CBR 设定法记为

MA, 基于规则的权重分配(RBA)及规则修正(RBR)设定法记为RBA & RBR, 遗传算法分配权重(GAA)和RBR修正设定法记为GA & RBR, 本文WFA分配权重及GDMR修正设定法记为WFA & GDMR. 对焙烧矿的单位时间产量(t/h)、质量(%)及每吨焙烧矿所消耗的能源(GJ/t)等指标的控制效果参看8天内的统计值变化情况, 如图5–7所示.

图5是单位时间产量的统计值对比, 可以看出, 本文的WFA & GDMR法虽然第6天的产量与RBA & RBR相比不占优势, 第3天和第5天比GAA & RBR方法要低, 但8天的产量平均值最高.

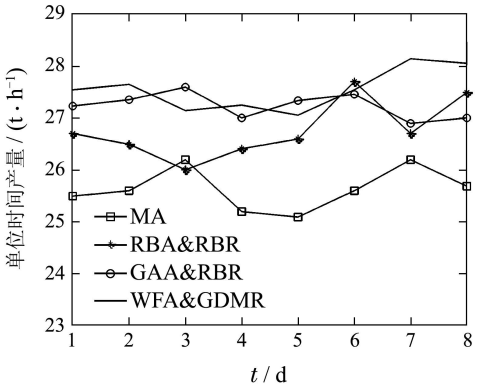

图 5 不同设定方法单位时间产量的对比

Fig. 5 Comparison among unit yield of the different setting methods

图6是焙烧矿质量指标的统计值对比, 可以看出, 本文提供的WFA&GDMR法虽然在第4天时的质量与RBA&RBR相比不占优势, 在第3天比GAA&RBR方法要低, 但在8天内的平均水平最高.

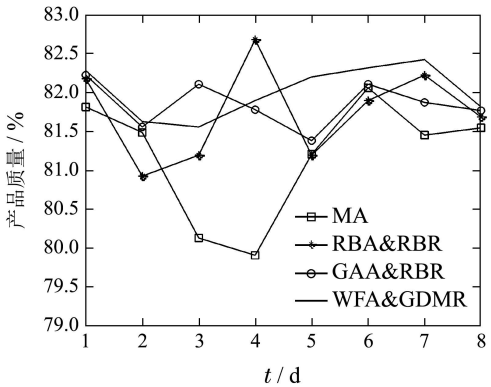

图 6 不同设定方法产品质量的对比

Fig. 6 Comparison among roasting ore quality of the different setting methods

图7是能耗指标的统计值对比, 可以看出, 本文提供的WFA & GDMR法虽然在第2天和第7天时的能耗比RBA & RBR要高, 在第3天和第6天比GAA & RBR方法要高, 但在8天内的能耗平均值最低.

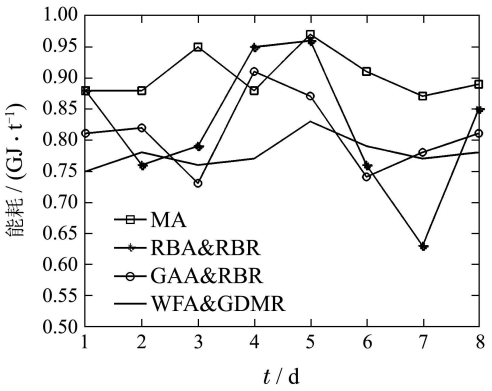

图 7 不同设定方法能耗指标的对比

Fig. 7 Comparison among energy consumption of the different setting methods

根据8天内的统计数据, 表1给出了这段时间内各指标的平均值对比结果. WFA & GDMR法的应用相比MA法、RBA & RBR法和GAA & RBR法来说, 焙烧矿的单位时间产量分别提高了1.92 t/h, 0.79 t/h和0.32 t/h, 焙烧矿的质量指标分别提高了0.81%, 0.26%和0.09%, 每吨产品的能耗指标分别下降了0.11 GJ/t, 0.03 GJ/t和0.02 GJ/t. 对比实验说明MA设定法在没有修正环节的参与时, 指标情况最差, 采用RBA或GAA分配权重和RBR修正后, 指标有了改善, 而本文的WFA分配权重与GDMR修正法的配合使用比前者的性能又有所改进.

表 1 不同设定方法生产指标统计平均值的对比

Table 1 Comparison among statistical average of product indices of the different setting methods

设定方法	产量/(t · h^{-1})	质量/%	能耗/(GJ · t^{-1})
MA	25.62	81.20	0.90
RBA & RBR	26.75	81.75	0.82
GAA & RBR	27.22	81.92	0.81
WFA & GDMR	27.54	82.01	0.79

5 结论(Conclusions)

本文对竖炉焙烧过程的CBR多变量设定模型进行了改进, 在设定值合理性的多目标评价基础上, 改进了变量权重的分配方法, 设计了群决策修正模型对设定值进行调整, 通过应用对比, 注水法分配权重及群决策修正方法的参与, 避免了专家定权及修正的缺陷, 说明本文的智能设定方法能够有效提高多目标评价设定模型的性能. 然而, 从实际运行效果来看, 还不能达到每天的生产指标均有良好的控制效果, 说明本文的方法还有改进的空间. 后续的研究重点则是变量权重的动态更新及群决策修正的自适应问题, 以增强设定模型的准确性, 适应性

和鲁棒性. 这也说明, 将CBR技术用于生产过程的控制时, 不仅要对过程机理进行深入分析, 掌握其特征, 而且要对CBR的学习机理进一步探索, 促使其学习能力不断提高.

参考文献(References):

[1] 严爱军, 柴天佑, 王普. 基于参量预报的磁选管回收率智能优化控制 [J]. 控制理论与应用, 2008, 25(5): 908 – 912.
(YAN Aijun, CHAI Tianyou, WANG Pu. Intelligently optimizing control of magnetic-tube-recovery-rate (MTRR) based on variable prediction [J]. *Control Theory & Applications*, 2008, 25(5): 908 – 912.)

[2] YAN A, CHAI T, YU W, et al. Multi-objective evaluation-based hybrid intelligent control optimization for shaft furnace roasting process [J]. *Control Engineering Practice*, 2012, 20(9): 857 – 868.

[3] CHAI T, WU F, DING J, et al. Intelligent work-situation fault diagnosis and fault-tolerant system for the shaft-furnace roasting process [J]. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 2007, 221(6): 843 – 855.

[4] CHAI T, DING J, WU F. Hybrid intelligent control for optimal operation of shaft furnace roasting process [J]. *Control Engineering Practice*, 2011, 19 (3): 264 – 275.

[5] CHAI T, ZHAO L, QIU J, et al. Integrated network-based model predictive control for setpoints compensation in industrial processes [J]. *IEEE Transactions on Industrial Informatics*, 2013, 9(1): 417 – 426.

[6] DIRKSZ D A, SCHERPEN J M A. Power-based setpoint control: experimental results on a planar manipulator [J]. *IEEE Transactions on Control Systems Technology*, 2012, 20(5): 1384 – 1391.

[7] HERNANDEZ-DEL-OLMO F, GAUDIOSO E, NEVADO A. Autonomous adaptive and active tuning up of the dissolved oxygen setpoint in a wastewater treatment plant using reinforcement learning [J]. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, 2012, 42(5): 768 – 774.

[8] GUERRERO J, GUISASOLA A, VILANOVA R, et al. Improving the performance of a WWTP control system by model-based setpoint optimization [J]. *Environmental Modelling and Software*, 2011, 26(4): 492 – 497.

[9] 罗小川. 钢水到达时间扰动下连铸机二冷过程设定值的优化方法 [J]. 控制理论与应用, 2012, 28(11): 1291 – 1300.
(LUO Xiaochuan. Optimization for set-point values in secondary cooling process with disturbance on job arriving time [J]. *Control Theory & Applications*, 2012, 28(11): 1291 – 1300.)

[10] 乔景慧, 周晓杰, 柴天佑. 水泥生料预分解过程智能优化设定控制 [J]. 控制理论与应用, 2011, 28(11): 1534 – 1540.
(QIAO Jinghui, ZHOU Xiaojie, CHAI Tianyou. Intelligent optimal-setting control for cement raw meal pre-calcining process [J]. *Control Theory & Applications*, 2011, 28(11): 1534 – 1540.)

[11] WANG W, LI H X, ZHANG J T. A hybrid approach for supervisory control of furnace temperature [J]. *Control Engineering Practice*, 2003, 11(11): 1325 – 1334.

[12] AMODT A, PLAZA E. Case-based reasoning: foundational issues, methodological variations, and system approaches [J]. *AI Communications*, 1994, 7(1): 39 – 59.

[13] LUO B, CUI Q, WANG H, et al. Optimal joint water-filling for coordinated transmission over frequency-selective fading channels [J]. *IEEE Communications Letters*, 2011, 15(2): 190 – 192.

[14] HENRIET J, LENI P E, LAURENT R, et al. Case-based reasoning adaptation of numerical representations of human organs by interpolation [J]. *Expert Systems with Applications*, 2014, 41(2): 260 – 266.

[15] YUE Z. Approach to group decision making based on determining the weights of experts by using projection method [J]. *Applied Mathematical Modelling*, 2012, 36(7): 2900 – 2910.

作者简介:

严爱军 (1970–), 男, 博士，副教授, 目前研究方向为过程建模与控制、人工智能及应用, E-mail: yanaijun@bjut.edu.cn;

黄晓倩 (1990–), 女, 硕士研究生, 目前研究方向为案例推理技术及应用, E-mail: hxq0407@emails.bjut.edu.cn.