

间歇生产过程的 R 调节学习控制

贾立¹, 施继平¹, 程大帅¹, 邱铭森²

(1. 上海大学 机电工程与自动化学院 上海市电站自动化技术重点实验室, 上海 200072;

2. 新加坡国立大学 工程学院, 新加坡 119260)

摘要: 针对间歇生产过程迭代学习控制难以进行跟踪性能分析的难题, 本文提出一种变 R 调节迭代学习控制算法, 借鉴经典控制理论定义有界跟踪和零跟踪概念. 以此研究能够让系统输出误差达到零跟踪的迭代学习控制策略, 并严格地证明了算法的性能, 得出可以通过调节权值 R 使过程产品质量的误差收敛到与模型精度相关联的有界区域的结论, 为相关理论结果实施于实际间歇过程提供了理论依据.

关键词: 间歇过程; 迭代学习; 零跟踪; 有界跟踪

中图分类号: TP273 **文献标识码:** A

R-adjustable learning control for batch process

JIA Li¹, SHI Ji-ping¹, CHENG Da-shuai¹, QIU Ming-Sen²

(1. College of Mechatronics Engineering and Automation, Shanghai University;

Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200072, China;

2. Faculty of Engineering, National University of Singapore, Singapore 119260)

Abstract: To track the operation performance of a batch process under iterative learning control, we propose an R -adjustment control strategy. The definitions of zero-tracking error and bounded-tracking error are given according to classical control theory. We investigate the iterative learning control strategy for achieving zero-tracking error in the output, and rigorously prove the tracking ability of the system under control. The most important conclusion is that the zero-tracking error can be achieved by the R -adjustment control strategy, which provides the basis for practical applications.

Key words: batch process; iterative learning; zero-tracking; bounded-tracking

1 引言(Introduction)

间歇过程的优化控制主要是以提高产品的质量、产量或缩短运行时间等为目标, 目标的实现由最佳操作轨线(过程中易于测量的控制变量)来保证^[1~4]. 由于间歇过程中具有显著的批次间重复特性, 因此迭代学习控制(iterative learning control)是解决间歇过程优化控制问题的一个重要途径^[5~8]. 但其在间歇过程的理论研究和实际应用方面还远未成熟, 如何将具有离散时间特征(批次轴)和连续时间特征(时间轴)的信息统一在学习型控制系统框架下还有待深入研究.

对于简单的间歇过程对象, 迭代学习优化问题可以利用极大值原理、变分法或动态规划求得问题的解析解. 但当间歇过程较为复杂时, 以上方法很难求得问题的解析解, 因而利用数值方法求解优化问题是必然的选择. 但是, 目前采用数值优化算法解决间歇过程的优化求解问题的研究成果中, 算法的收敛

性大多数都是从仿真结果上来说明, 没有从数学的角度给出严格的数学证明. 因此, 有必要从数学的角度研究算法的收敛性和跟踪性能.

针对上述问题, 笔者在前期研究工作^[9]中, 主要讨论了间歇过程迭代学习控制器在批次轴上的收敛性能, 并给出了严格的数学证明. 但是在实际中仅仅满足收敛性是不够的, 还要使实际的终点产品质量的跟踪误差达到最小. 因此, 本文在前期研究工作的基础上, 对间歇过程终点产品质量跟踪误差进行分析, 提出了采用动态 R 调节的迭代学习控制策略, 即通过动态调节目标函数中的权值 R , 能使产品质量输出误差实现零跟踪. 分析表明, 当 R 满足一定的条件, 就能保证优化控制算法的收敛性.

2 间歇生产过程的迭代学习控制策略(Iterative learning control for batch processes)

在本文研究中, 给出如下定义: k 表示批次; t 表示批次内的离散时间点; u_k 表示第 k 批次的输入序列;

收稿日期: 2010-05-05; 收修改稿日期: 2011-03-09.

基金项目: 国家自然科学基金资助项目(61004019); 上海市科委地方高校专项基金资助项目(08160512100); 上海市基础研究重点资助项目(09JC1406300); 教育部博士点基金资助项目(20093108120013); 上海市教育委员会科研创新资助项目(09YZ08); 上海大学“十一五”211建设资助项目.

$\hat{y}_{k+1}(t)$ 表示第 $k+1$ 批次在 t 时刻的产品质量的预测值; $\hat{e}_k^f = y_k^f - \hat{y}_k^f$ 表示模型终点质量的预测误差; $\bar{e}_k^f = \frac{1}{k} \sum_{i=1}^k \hat{e}_i^f$ 表示模型终点质量的平均预测误差; $\tilde{y}_{k+1}^f = \hat{y}_{k+1}^f + \frac{\alpha}{k+1} \bar{e}_k^f (\alpha \geq 0)$ 表示第 $k+1$ 批次模型终点质量的修正值。

为实现产品终点质量 y_d^f 的最优控制, 构造由 $\tilde{e}_{k+1}^f = y_d^f - \tilde{y}_{k+1}^f$ 和 $\Delta \mathbf{u}_{k+1} = \mathbf{u}_{k+1} - \mathbf{u}_k$ 组成的二次型目标函数

$$\min_{\mathbf{u}_{k+1} \in \Theta_U} J(\mathbf{u}_{k+1}, k+1) = \|\tilde{e}_{k+1}^f\|_Q^2 + \|\Delta \mathbf{u}_{k+1}\|_R^2. \quad (1)$$

在实际工业生产过程中有 $u^{\text{low}} \leq \mathbf{u}_{k+1}(t) \leq u^{\text{up}}$, 这里 u^{low} 和 u^{up} 分别表示输入控制序列的下界和上界, Q 和 R 表示权值矩阵, 分别为: $Q = q \cdot I$, $R = r \cdot I$ (r 和 q 为正标量). 在以下描述中, 将上述优化控制策略简称为OPT算法。

这里需要指出, 本文的研究工作是要解决间歇过程批次轴优化控制问题的数学模型化, 即由式(1)描述; 然后进行性能分析, 下一章节分析当 R 满足一定的条件, 就能保证优化控制算法的收敛, 即可以保证 $\|e(\mathbf{u}_k)\|_Q^2$ 收敛。

注1 式(1)描述的优化控制策略的求解方法和实际间歇过程的复杂度有关. 对于简单的过程对象, 优化问题可以利用极大值原理、变分法或动态规划求得问题的解析解. 但当间歇过程较为复杂时, 以上方法很难求得问题的解析解, 因而利用数值方法求解优化问题是必然的选择. 但是, 目前采用数值优化算法解决间歇过程的优化求解问题的研究成果中, 算法的收敛性大多数都是从仿真结果上来说明, 没有从数学的角度给出严格的数学证明。

3 性能分析(Performance analysis)

对实际的间歇生产过程, 最优解决方案的目标是保证产品终点质量跟踪误差趋于0, 即

$$\lim_{k \rightarrow \infty} e(\mathbf{u}_k) = \lim_{k \rightarrow \infty} (y_d^f - y_k^f) = 0.$$

这里, 假设最优值的求解精度满足要求. 因此, OPT算法可以简化为式(2)(3):

$$\min_{\mathbf{u}_{k+1} \in \Theta_U} J(\mathbf{u}_{k+1}, k+1) = \|\mathbf{e}(\mathbf{u}_{k+1})\|_Q^2 + \|\mathbf{u}_{k+1} - \mathbf{u}_k\|_R^2, \quad (2)$$

$$u^{\text{low}} \leq \mathbf{u}_{k+1}(t) \leq u^{\text{up}}, \quad (3)$$

其中 $\mathbf{e}(\mathbf{u}_{k+1}) = y_d^f - y_{k+1}^f$. 为叙述方便, 将由式(2)(3)描述的迭代优化控制策略称为OPT*算法。

在式(2)(3)描述的目标目标函数中, 令 M^* 为 $\|\mathbf{e}(\cdot)\|_Q^2$ 的最小值(M^* 的理想值为零), $Q = q \cdot I$, $R = r_k \cdot I$. 其中: r_k 有界并且其上界为 M_r , I 为 T 维单位矩阵。

由于实际问题和模型的多样性, 使得OPT*问题中的极限值对初始参数的依赖程度比较大, 极易使

其陷入局部最优解, 也就是说即使是在模型-系统零误差以及每批次总能搜索到最优解这种理想条件下, 产品的终点质量跟踪误差由于初始点的影响也不一定保证总能够趋于0. 针对该问题, 下面将引入具有变 R 调节的迭代学习控制策略使收敛到0.

定义1 对任意的 $\varepsilon > 0$, 存在 $\delta = \delta(\varepsilon) > 0$, 使得当 $r_{k_0+1} < \delta$ 时有 $|||e(\mathbf{u}_k)\|_Q^2 - M^*| < \varepsilon$ 对任意 $k > k_0$ 成立, 则称OPT*算法的解使得系统是有界跟踪的。

定义2 若OPT*算法的解使得系统是有界跟踪的, 且存在 $\delta > 0$, 当 $r_{k_0+1} < \delta$ 时有

$$\lim_{k \rightarrow \infty} |||e(\mathbf{u}_{k+1})\|_Q^2 - M^*| = 0$$

对任意 $k > k_0$ 成立, 则称OPT*算法的解使系统是有界跟踪的. 则称OPT*算法的解使系统是零跟踪的。

定理1 由式(2)(3)描述的OPT*算法收敛, 即

$$\lim_{k \rightarrow \infty} \|\Delta \mathbf{u}_k\|_R^2 = 0.$$

证 因为

$$\|e(\mathbf{u}_{k+1})\|_Q^2 \leq J(\mathbf{u}_{k+1}, k+1) \leq J(\mathbf{u}_k, k+1) = \|e(\mathbf{u}_k)\|_Q^2,$$

则 $\|e(\mathbf{u}_k)\|_Q^2$ 的极限存在, 且有

$$\lim_{k \rightarrow \infty} \|e(\mathbf{u}_k)\|_Q^2 = \lim_{k \rightarrow \infty} J(\mathbf{u}_k, k).$$

因此, 可以得

$$\lim_{k \rightarrow \infty} \|\Delta \mathbf{u}_k\|_R^2 = \lim_{k \rightarrow \infty} (J(\mathbf{u}_k, k) - \|e(\mathbf{u}_k)\|_Q^2) = 0.$$

证毕。

定理2 对于任意 k_0 时刻的解 $\mathbf{u}_{k_0}$ 和任意的 $\varepsilon > 0$, 存在 $\delta = \delta(\varepsilon) > 0$, 当 $r_{k_0+1} < \delta$ 时 $k_0 + 1$ 批次的最优解总满足 $\mathbf{u}_{k_0+1} \in \Theta_1$, 其中

$$\Theta_1 = \{\mathbf{u}_{k_0+1} \mid |||e(\mathbf{u}_{k_0+1})\|_Q^2 - M^*| < \varepsilon\}.$$

证 定义空间

$$\Theta_2 = \{\mathbf{u}_{k_0+1} \mid |||e(\mathbf{u}_{k_0+1})\|_Q^2 - M^*| \geq \varepsilon\},$$

并将 Θ_1 分为如下两部分:

$$\Theta_1^1 = \{\mathbf{u}_{k_0+1} \mid |||e(\mathbf{u}_{k_0+1})\|_Q^2 - M^*| < \frac{\varepsilon}{2}\},$$

$$\Theta_1^2 = \{\mathbf{u}_{k_0+1} \mid \frac{\varepsilon}{2} \leq |||e(\mathbf{u}_{k_0+1})\|_Q^2 - M^*| < \varepsilon\}.$$

由于对于任意的 $\varepsilon > 0$, 总存在 $\delta(\varepsilon) > 0$ 使得

$$\max_{\mathbf{u} \in \Theta_U} \|\mathbf{u} - \mathbf{u}_{k_0}\|_{\delta(\varepsilon) \cdot I}^2 < \frac{\varepsilon}{2},$$

则当 $r_{k_0+1} < \delta$ 时必然有 $\|\mathbf{u} - \mathbf{u}_{k_0}\|_{R_{k_0+1}}^2 < \frac{\varepsilon}{2}$, 任意 $\mathbf{u} \in \Theta_U$.

因为, 对任意一个 $\mathbf{u}_1 \in \Theta_1^1$ 都有

$$|||e(\mathbf{u}_1)\|_Q^2 - M^*| = \|e(\mathbf{u}_1)\|_Q^2 - M^* < \frac{\varepsilon}{2},$$

并且对任意一个 $\mathbf{u}_2 \in \Theta_2$ 都有 $|||e(\mathbf{u}_2)\|_Q^2 - M^*| =$

$\|e(\mathbf{u}_2)\|_Q^2 - M^* \geq \varepsilon$. 所以有

$$\begin{aligned} & \|e(\mathbf{u}_1)\|_Q^2 - \|e(\mathbf{u}_2)\|_Q^2 = \\ & (\|e(\mathbf{u}_1)\|_Q^2 - M^*) - (\|e(\mathbf{u}_2)\|_Q^2 - M^*) < -\frac{\varepsilon}{2}, \end{aligned}$$

进而有

$$\begin{aligned} & J(\mathbf{u}_1, k_0 + 1) - J(\mathbf{u}_2, k_0 + 1) = \\ & \|e(\mathbf{u}_1)\|_Q^2 - \|e(\mathbf{u}_2)\|_Q^2 + \left(\frac{\|\mathbf{u}_1 - \mathbf{u}_{k_0}\|_{R_{k_0+1}}^2}{- \|\mathbf{u}_2 - \mathbf{u}_{k_0}\|_{R_{k_0+1}}^2} \right) < 0, \end{aligned}$$

因此, 在第 $k_0 + 1$ 批次得到的最优解不可能落在 Θ_2 上, 即 $\mathbf{u}_{k_0+1} \in \Theta_1$. 证毕.

定理 3 从任意 k_0 时刻的解 $\mathbf{u}_{k_0}$ 出发, OPT* 算法的解使得系统是有界跟踪的.

证 根据定理 2 可知对于任意 k_0 时刻的解 $\mathbf{u}_{k_0}$ 和任意的 $\varepsilon > 0$, 存在 $\delta = \delta(\varepsilon) > 0$, 当 $r_{k_0+1} < \delta$ 时 $k_0 + 1$ 批次的最优解满足 $\|e(\mathbf{u}_{k_0+1})\|_Q^2 - M^* < \varepsilon$. 由于对任意批次 k 总有下式成立:

$$\begin{aligned} & \|e(\mathbf{u}_{k+1})\|_Q^2 \leq J(\mathbf{u}_{k+1}, k+1) \leq \\ & J(\mathbf{u}_k, k+1) = \|e(\mathbf{u}_k)\|_Q^2. \end{aligned}$$

可以得到, 对任意的 $k > k_0 + 1$ 总有

$$\|e(\mathbf{u}_k)\|_Q^2 - M^* < \|e(\mathbf{u}_{k_0+1})\|_Q^2 - M^* < \varepsilon.$$

因此, 对任意 $k > k_0$ 总有

$$|\|e(\mathbf{u}_k)\|_Q^2 - M^*| = \|e(\mathbf{u}_k)\|_Q^2 - M^* < \varepsilon$$

成立. 所以, 对于任意初始解 $\mathbf{u}_{k_0}$, OPT* 算法(3)的解使得系统是有界跟踪的. 证毕.

定理 4 若函数 $g(\cdot) = \|e(\cdot)\|_Q^2$ 可导且最优解不在边界处(即在其极值点处), 则从任意 k_0 时刻的解 $\mathbf{u}_{k_0}$ 出发, OPT* 算法的解使得系统是零跟踪的.

证 根据定理 3 可知, 从任意 k_0 时刻的解 $\mathbf{u}_{k_0}$ 出发, 上述迭代优化问题是有界跟踪的.

令函数 $g(\cdot)$ 最优值为其极值点 $(\mathbf{u}^*, M^*)$, 考虑 $\mathbf{u}^*$ 的一个微小的邻域 $\Theta_{\mathbf{u}^*}$ (若 $g(\cdot)$ 有多个相等的最优值, 则可以视为这些最优值点的并集)使得该邻域内除最优解外无其他极值点. 由于函数 $g(\cdot)$ 的最优解不在 $\Theta_{\mathbf{u}}$ 的边界处, 则必可以找到一个集合 $\Theta_{\mathbf{u}^*}$ 不包含 $\Theta_{\mathbf{u}}$ 的边界. 即 $\Theta_{\mathbf{u}^*} = \{\mathbf{u} \mid |\|e(\mathbf{u}_k)\|_Q^2 - M^*| < \varepsilon\}$. 并且对于任何 $\mathbf{u} \in \Theta_{\mathbf{u}^*}$ 都不包含 $\Theta_{\mathbf{u}}$ 的边界. 根据定理 2 可知对于上述 ε , 存在 $\delta > 0$, 当 $r_{k_0+1} < \delta$ 时, 对于任意的初值 $\mathbf{u}_{k_0}$, 当 $k > k_0$ 时总有 $|\|e(\mathbf{u}_k)\|_Q^2 - M^*| < \varepsilon$, 即 $\mathbf{u}_k \in \Theta_{\mathbf{u}^*}$, 则 $\mathbf{u}_k$ 不包含 $\Theta_{\mathbf{u}}$ 的边界. 因此 $k > k_0$ 后每批次得到的最优解 $\mathbf{u}_k$ 只能为

$$J(\mathbf{u}_k, k) = \|e(\mathbf{u}_k)\|_Q^2 + \|\mathbf{u}_k - \mathbf{u}_{k-1}\|_R^2$$

在开集 $\Theta_{\mathbf{u}^*}$ 内的极值点, 不可能为 $\Theta_{\mathbf{u}}$ 的边界处.

因此当 $k > k_0$ 时, 最优解 $\mathbf{u}_k$ 满足

$$\frac{\partial J(\mathbf{u}_k, k)}{\partial \mathbf{u}_k} = \frac{\partial \|e(\mathbf{u}_k)\|_Q^2}{\partial \mathbf{u}_k} + 2r_k(\mathbf{u}_k - \mathbf{u}_{k-1}) = 0.$$

由定理 1 可知 $\lim_{k \rightarrow \infty} r_k(\mathbf{u}_k - \mathbf{u}_{k-1}) = 0$, 因此有

$$\lim_{k \rightarrow \infty} \frac{\partial \|e(\mathbf{u}_k)\|_Q^2}{\partial \mathbf{u}_k} = 0,$$

即 $\|e(\mathbf{u}_k)\|_Q^2$ 收敛到其极值点. 由于 $\mathbf{u}_k \in \Theta_{\mathbf{u}^*}$, 且函数 g 在 $\Theta_{\mathbf{u}^*}$ 内除最优值外无其他极值点, 因此 $\|e(\mathbf{u}_k)\|_Q^2$ 收敛到其最优值, 即

$$\begin{aligned} & \lim_{k \rightarrow \infty} |\|e(\mathbf{u}_{k+1})\|_Q^2 - M^*| = \\ & \lim_{k \rightarrow \infty} \|e(\mathbf{u}_{k+1})\|_Q^2 - M^* = 0. \end{aligned}$$

证毕.

以上分析是针对模型零误差的情况, 考虑到实际中的误差的影响, 这里取 R 为动态参数:

$$R = r \cdot I, \quad r = \tau_1 [1 - \exp(-\tau_2 |\bar{e}_k^f|)], \quad (4)$$

其中 τ_1 和 τ_2 为常数. 从式(4)可以看出, r 的大小变化由 $|\bar{e}_k^f|$ 决定, 当 $|\bar{e}_k^f|$ 减小到 0 时, r 也减小 0, 这也就是说模型的精确度决定了当前批次的最优解, 即最优解将收敛到一个由模型误差确定的区域中. 由于模型和实际系统不可能完全匹配, 如果在迭代初期选取较小的 r 将会造成系统输出陷入局部最优解(即模型-系统失配情况下的全局最优解). 因此, 可以将 r 设计成关于模型和系统预测误差均值的单调下降函数, 这样随着模型精度的提高, r 将会逐渐下降, 系统的输出则会随着迭代批数的增加而趋近期望值.

分析表明, 本文提出的动态 R 调节的迭代学习控制策略是收敛的, 这为间歇过程的应用实施提供了实践依据.

注 2 本文研究结论与实际具体的间歇过程有一定的关系, 间歇过程模型精确度影响式(2)中的误差项, 进而影响最终优化控制算法的性能, 当模型误差满足一定的条件可保证系统达到零跟踪. 另外, 模型的精确程度实际上也实际间歇过程的复杂度, 也就是说实际间歇过程的复杂度将直接影响最终优化控制算法的性能.

注 3 本文的研究结果适用于非线性间歇过程, 这是与文献[10]的主要区别.

4 仿真分析(Simulation analysis)

将本文提出的算法用于典型的间歇反应器中^[11]:

$$\begin{cases} \dot{x}_1 = -4000 \exp\left(\frac{-2500}{T}\right)x_1^2, \\ \dot{x}_2 = 4000 \exp\left(\frac{-2500}{T}\right)x_1^2 - \\ \quad 6.2 \cdot 10^5 \exp\left(\frac{5000}{T}\right)x_2, \end{cases} \quad (5)$$

其中: x_1 和 x_2 分别表示无量纲浓度; T 表示反应温度.

仿真研究中对 T 进行无量纲化, 即 $T_d = (T - T_{\min})/(T_{\max} - T_{\min})$, 其中 $T_{\min}$ 和 $T_{\max}$ 分别为 298 K 和 398 K. 设初始条件为: $x_1(0) = 1$, $x_2(0) = 0$, 选择控制变量为 $T_d(0 \leq T_d \leq 1)$; 输出变量为 $x_2(t)$. 本研究目标是要最大化反应物 B 的终点浓度 $x_2(t_f)$.

表1列出了仿真中的一些参数值。

表1 仿真参数及参数值

Table 1 The parameters in simulation

参数	参数值	参数	参数值
τ_1	1	α	0.6
τ_2	10	β	0.01
q	10	p_1	1000
窗口长度	5		

图1表示模型和实际测量的产品质量终点误差曲线, 整个反应时间段内误差的RMSE和MAXE值曲线。可以看到仿真中建立的模型经修正后具有较高的精度, 这使得后续的优化跟踪控制有望达到满意效果。图2给出了相应的误差跟踪轨迹和 ΔU_K 轨迹。20批次之后产品质量输出可达到0.61, 跟踪误差仅为 1.4×10^5 。以上仿真结果表明, 可以通过调节权值 R 使过程产品质量的误差收敛到与模型精度相关的有界区域, 从而满足实际的生产需求。




图1 模型和系统之间误差情况

Fig. 1 The error between model and batch process




图2 系统误差跟踪轨迹和 $\max_{i=1}^{10} (|\Delta u_k(i)|)$ 轨迹

Fig. 2 The tracking error of the batch process and the tracking of $\max_{i=1}^{10} (|\Delta u_k(i)|)$

5 总结(Conclusions)

本文研究了能够让系统输出误差达到零跟踪的迭代学习控制策略, 并严格地证明了算法的稳定性。

主要贡献是讨论了什么条件下能够使得终点产品质量跟踪误差收敛到一个界内, 何时能够使得终点产品质量跟踪误差收敛到零, 并且分析了在变 R 调节的情况下终点产品质量跟踪误差能够收敛到零。仿真结果验证了本文算法的有效性和潜在实用价值。

参考文献(References):

- [1] 陆宁云, 王福利, 高福荣, 等. 间歇过程的统计建模与在线监测[J]. 自动化学报, 2006, 32(3): 400 – 410.
(LU Ningyun, WANG Fuli, GAO Furong, et al. Statistical modeling and online monitoring for batch processes[J]. *Acta Automatic Sinica*, 2006, 32(3): 400 – 410.)
- [2] XIONG Z H, ZHANG J, WANG X, et al. Integrated tracking control strategy for batch processes using a batch-wise linear time-varying perturbation model[J]. *IET Control Theory & Applications*, 2007, 1(1): 179 – 188.
- [3] LUN, GAO F. Stage-based process analysis and quality prediction for batch processes[J]. *Industrial and Engineering Chemistry Research*, 2005, 44(10): 3547 – 3555.
- [4] 张杰, JEROME N, 熊智华. 基于时变偏扰模型的间歇过程迭代学习控制[J]. 清华大学学报(自然科学版), 2008, 48(S2): 1771 – 1774.
(ZHANG Jie, JEROME N, XIONG Zhihua. Iterative learning control of batch processes based on time varying perturbation models[J]. *Journal of Tsinghua University(Science and Technology)*, 2008, 48(S2): 1771 – 1774.)
- [5] OWENS D H, HA J. Iterative learning control – an optimization paradigm[J]. *Annual Reviews in Control, Annual Reviews in Control*, 2005, 29(1): 57 – 70.
- [6] LEE J H, LEE K S. Iterative learning control applied to batch processes: an overview[J]. *Control Engineering Practice*, 2007, 15(10): 1306 – 1318.
- [7] 王树青, 张学鹏, 陈良. 半导体生产过程的Run-to-Run控制技术综述(工学版)[J]. 浙江大学学报, 2008, 42(8): 1393 – 1398.
(WANG Shuqing, ZHANG Xuepeng, CHENG Liang. Review on Run-to-Run control in semiconductor manufacturing[J]. *Journal of Zhejiang University(Engineering Science)*, 2008, 42(8): 1393 – 1398.)
- [8] KWON Y D, EVANS L B. A coordinate transformation method for the numerical solution of nonlinear minimum-time control problems[J]. *AIChE Journal*, 1975, 21(3): 1158 – 1164.
- [9] 贾立, 施继平, 邱铭森. 一类间歇生产过程的迭代学习控制算法及其收敛性分析[J]. 化工学报, 2010, 61(1): 116 – 123.
(JIA Li, SHI Jiping, QIU Mingsen. An iterative learning control algorithm with convergence analysis for batch process[J]. *Journal of Chemical Industry and Engineering*, 2010, 61(1): 116 – 123.)
- [10] GAO Furong, YANG Yi, SHAO Cheng. Robust iterative learning control with applications to injection molding process[J]. *Chemical Engineering Science*, 2001, 56(24): 7025 – 7034.
- [11] XIONG Z H, ZHANG J, WANG X, et al. Run-to-run iterative optimization control of batch processes based on recurrent neural network[J]. *Advances in Neural Networks*, 2004, 3174: 97 – 103.

作者简介:

贾立 (1975—), 女, 副教授, 研究方向为复杂系统的建模与优化控制, E-mail: jiali@staff.shu.edu.cn;

施继平 (1985—), 男, 硕士, 研究方向为复杂系统的建模与优化控制, E-mail: sjp1985@163.com;

程大帅 (1984—), 男, 硕士, 研究方向为复杂系统的建模与优化控制, E-mail: ysring@163.com;

邱铭森 (1961—), 男, 副教授, 研究方向为复杂系统的建模与优化控制, E-mail: checms@shu.edu.cn.