

控制与决策

Control and Decision

基于互信息操作变量曲线参数化的间歇过程批内修正优化

栾小丽, 刘晓凤, 刘飞

引用本文:

栾小丽, 刘晓凤, 刘飞. 基于互信息操作变量曲线参数化的间歇过程批内修正优化[J]. *控制与决策*, 2021, 36(1): 234–240.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.0825>

您可能感兴趣的其他文章

Articles you may be interested in

考虑个体累积共识贡献的犹豫模糊语言自适应共识模型

Adaptive consensus model with hesitant fuzzy linguistic information considering individual cumulative consensus contribution

控制与决策. 2021, 36(1): 187–195 <https://doi.org/10.13195/j.kzyjc.2019.0556>

基于改进萤火虫算法的区域交通信号配时优化

Timing optimization of regional traffic signals based on improved firefly algorithm

控制与决策. 2020, 35(12): 2829–2834 <https://doi.org/10.13195/j.kzyjc.2019.1835>

事件触发机制下分布时滞网络化控制系统 H_∞ 故障检测

Event-triggered H_∞ fault detection for networked control systems with distributed delays

控制与决策. 2020, 35(12): 3059–3065 <https://doi.org/10.13195/j.kzyjc.2019.0456>

基于高炉炉况评价和反馈补偿的喷煤量决策优化

Decision-making optimization of coal injection volume based on evaluation of blast furnace condition

控制与决策. 2020, 35(11): 2803–2809 <https://doi.org/10.13195/j.kzyjc.2018.1553>

基于无标签、不均衡、初值不确定数据的设备健康评估方法

Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition

控制与决策. 2020, 35(11): 2687–2695 <https://doi.org/10.13195/j.kzyjc.2018.1493>

基于互信息操作变量曲线参数化的 间歇过程批内修正优化

栾小丽[†], 刘晓凤, 刘 飞

(江南大学 物联网工程学院, 江苏 无锡, 214122)

摘 要: 针对间歇过程批次内扰动影响最终优化效果的问题, 提出一种基于互信息操作变量曲线参数化的间歇过程批内修正优化方法. 首先根据操作变量与指标变量间互信息和相关系数划分出操作变量曲线上对指标变量作用近似的时段; 然后, 结合操作变量曲线的形态特征选择有代表性参数建立优化模型, 以降低优化模型求解的复杂度. 考虑到生产过程噪声干扰影响最终优化效果, 在批次内设置决策点, 并根据当前工况信息对决策点后未实施的操作变量曲线进行调整, 以减弱批次内扰动对最终优化效果的影响. 最后, 将所提出方法用于某一化工厂双酚 A 结晶过程的优化研究, 通过仿真结果验证了该方法的有效性.

关键词: 间歇过程; 批内修正优化; 操作变量曲线参数化; 互信息

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.0825

开放科学(资源服务)标识码(OSID):



引用格式: 栾小丽, 刘晓凤, 刘飞. 基于互信息操作变量曲线参数化的间歇过程批内修正优化 [J]. 控制与决策, 2021, 36(1): 234-240.

Intra-batch correction optimization of batch process with manipulated variable trajectory parameterization based on mutual information

LUAN Xiao-li[†], LIU Xiao-feng, LIU Fei

(School of Internet of Things, Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at the problem that the intra-batch disturbance of batch processes affects the end-point optimization effect, a method of intra-batch correction optimization of batch process with manipulated variable trajectory parameterization based on mutual information is proposed. According to the mutual information and correlation coefficient between the manipulated variable and the index variable, the time period on the manipulated trajectory that has a similar effect on index variable is divided. Then, combine with the morphological characteristics of the manipulated variable trajectory, fewer parameters are selected to establish an optimization model to reduce the complexity of optimization model solution. Considering that noise interference in the production process affects the final optimization effect, the decision point is set in the batch and the unimplemented manipulated variable trajectory after the decision point is adjusted according to the current working condition information to reduce the impact of intra-batch disturbances on the final optimization effect. Finally, the proposed method is applied to the optimization of crystallization process of bisphenol A in a chemical plant. The simulation results validate the effectiveness of the method.

Keywords: batch processes; intra-batch correction optimization; manipulated variable trajectory parameterization; mutual information

0 引言

间歇过程是现代工业生产的重要生产方式^[1-2], 生产的产品遍布食品、药品、化工等众多领域^[3-4]. 在完成有效动态控制基础上, 优化间歇过程操作变量曲线(manipulated variable trajectory, MVT)成为提高效

益的重要手段^[5].

目前, 国内外针对间歇过程的优化研究一般都是在建立过程模型的基础上求解最优操作变量曲线^[6]. 如基于过程机理模型的优化方法, 这种建模方法一般需要掌握相关的专业知识, 而且一些过程要

收稿日期: 2019-06-10; 修回日期: 2019-08-28.

基金项目: 国家自然科学基金项目(61722306, 61833007).

责任编委: 张海涛.

[†]通讯作者. E-mail: xlluan@jiangnan.edu.cn.

建立精确的机理模型十分困难而且费用昂贵^[7]. 近年来,随着传感检测技术发展与计算机存储能力的提高^[8],基于数据的经验建模方法被广泛用于间歇过程优化^[9]. 根据有无批次内信息反馈,又可以将这一方法大致分为两类:第1类是批次到批次的间歇过程优化方法,如邸丽清等^[10]、黄碧璇等^[11]采用偏最小二乘(partial least squares, PLS)方法建立指标预测模型,批次到批次地更新操作变量曲线. 考虑过程的非线性, Li等^[12]提出了一种非线性偏最小二乘建模方法;贾润达等^[13]以核偏最小二乘算法建模,批次到批次迭代优化操作变量曲线. 但是这种优化方法缺少及时的批次内信息反馈,致使批次内噪声干扰影响最终优化效果. 为了解决这一问题, Flores-Cerillo等^[5]提出了一种批次内修正优化策略,该方法在过程的不同位置设置决策点,并在每一决策点上根据当前指标预测值与期望值的偏差对未实施的操作变量曲线进行调整. Jia等^[14]改进了这一方法中的推理质量模型,采用序贯正交偏最小二乘算法预测每一决策点上的终点指标. 以上操作变量曲线的调整策略中,一般是先将操作变量等连续性变量轨迹离散化为若干段,然后调整各段使得终点指标变量趋于期望值. 但是,对于较长周期的生产过程,如果划分段数过多,则较多的参数会增加计算负担,也会使得优化算法不稳定^[15];如果划分段数过少,则这些参数可能并不足以描述曲线特征.

针对上述问题,本文提出一种基于互信息操作变量曲线参数化的间歇过程批内修正优化方法. 通过计算操作变量与指标变量间的互信息和相关系数,选出有代表性的参数用于优化分析. 考虑批次内噪声干扰会影响最终优化效果,提出一种带约束的间歇过程批内修正优化方法,该方法根据当前工况信息对未实施的操作变量曲线进行调整,确保最终指标优化效果. 最后,将所提出的优化方法用于双酚A结晶过程产品产量的优化研究,通过仿真结果验证所提出优化方法在间歇过程中应用的可行性与有效性.

1 操作变量曲线参数化

间歇过程优化问题本质上是一个动态非线性优化问题,不失一般性,间歇过程的优化问题通常可以描述为如下形式:

$$\begin{aligned} & \min_{s(t)} \psi[(\varpi(t_f))]. \\ & \text{s.t.} \begin{cases} \dot{\varpi} = F(\varpi, s(t)), \varpi(0) = \varpi_0; \\ \Phi(\varpi, s(t)) \leq 0. \end{cases} \end{aligned} \quad (1)$$

其中: ψ 为被最小化的过程性能指标, $s(t)$ 为操作变量轨迹, ϖ 为系统状态变量, t_f 为终端时刻, F 为描述系统动态性的函数, ϖ_0 为已知初始条件, Φ 为路径约束. 式(1)是一个难以直接求解的无穷维优化问题,因而一般需要对其进行简化. 常用的手段是将优化模型中操作变量等连续性变量进行分段离散化处理,从而将这一动态优化问题转化为下式描述的静态优化问题:

$$\begin{aligned} & \min_{\{s_l|l=1,2,\dots,\tilde{M}\}} \psi[(\varpi(t_f))]. \\ & \text{s.t.} \begin{cases} \varpi_{l+1} = F(\varpi_l, s_l), \varpi(0) = \varpi_0; \\ \Phi(\varpi_l, s_l) \leq 0. \end{cases} \end{aligned} \quad (2)$$

其中: $\{s_l|l=1,2,\dots,\tilde{M}\}$ 为待优化的操作变量曲线参数集合, s_l 为第 l 个操作变量, \tilde{M} 为参数的数目, ϖ_l 为第 l 个状态变量. 式(2)中变量曲线分段离散化较常用的方法为阶跃式分段常数参数化方法^[16],根据该方法变量,曲线离散化的每一时段可以采用一个常

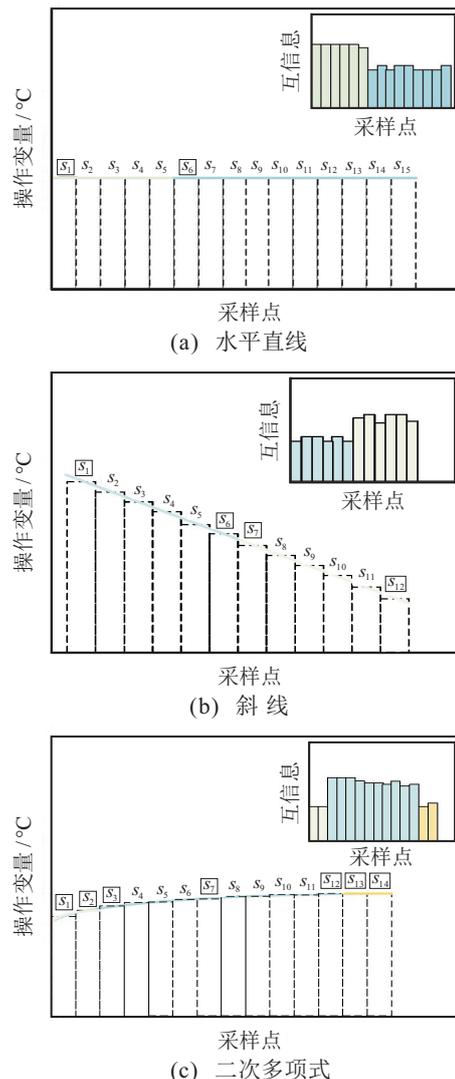


图1 操作变量曲线参数化示意

参数表征,优化模型通过对这些参数的调整,获得优化的操作变量曲线。但是,目前该参数化方法并无较好的划分段数的依据,针对这一问题,本文根据操作变量曲线各时段对优化指标贡献程度及曲线的形态特征,提出一种基于互信息的操作变量曲线参数化方法。

下面以图1中几种基本形态下的操作变量曲线参数化为例,详细说明本文提出的基于互信息的操作变量曲线参数化方法。图1分别描述了形态为水平直线、斜线、二次多项式型操作变量曲线。首先,将操作变量曲线进行分段常数参数化处理,按固定采样时间对曲线进行分段,由此,图1(a)中操作变量曲线可采用参数集 $[s_1, s_2, \dots, s_{15}]$ 描述,图1(b)中操作变量曲线可采用参数集 $[s_1, s_2, \dots, s_{12}]$ 描述,图1(c)中操作变量曲线可采用参数集 $[s_1, s_2, \dots, s_{14}]$ 描述。

为了选出有代表性的参数对操作变量曲线进行表征,本文首先采用互信息^[17-18]计算操作变量与指标变量间的相关性。

1.1 互信息理论

互信息是一个随机变量对包含另一个随机变量信息量的度量,互信息越大,两个变量之间的相关性越强。计算式可以写为如下形式:

$$\tilde{I}(S; Y) = \sum_{s \in R} \sum_{y^* \in Y} f(s, y^*) \log \frac{f(s, y^*)}{f^*(s) f^*(y^*)}. \quad (3)$$

其中: S 、 Y 为离散型随机变量, $f^*(s)$ 表示 s 的概率密度函数, $f^*(y^*)$ 表示 y^* 的概率密度函数, $f(s, y^*)$ 表示 s 与 y^* 的联合概率密度, $\tilde{I}(S; Y)$ 表示随机变量 S 、 Y 之间的互信息。算法详细推导过程可以参见文献[19]。

1.2 基于互信息的参数化方法

根据式(3)计算各操作变量与终点指标间的互信息。进一步,考虑到工业生产出于安全角度,所设定的操作变量曲线一般不会大幅度改变,但是操作变量曲线较小的变动都能在测量变量曲线上得到体现,因而,本文通过计算测量变量曲线离散化的各段与指标变量间的互信息来分析不同时段操作变量与指标变量间作用关系。若图1各操作变量与指标变量间互信息计算结果如各自右上角子图所示,而后根据采样的时间顺序,依次判断相邻的操作变量对指标变量贡献程度的差异,则当贡献度差异超过下式设定的阈值时,此区间划分完毕,进入下一参数化区间的划分:

$$\tilde{I}(\hat{m}_i; y) - \tilde{I}(\hat{m}_{i+\lambda}; y) < h_m. \quad (4)$$

其中: \hat{m}_i 为测量变量曲线的第 i 个时段变量; y 为终点指标变量; $\tilde{I}(\hat{m}_i; y)$ 为 \hat{m}_i 与 y 间的互信息; $\hat{m}_{i+\lambda}$ 为测

量变量曲线的第 $i + \lambda$ 个时段变量, $\lambda \in N^*$ 为正整数; h_m 为过程的第 m 个阶段下的自定义阈值。若式(4)成立时 λ 的最大值为 λ^* ,则 $[i, i + \lambda^*]$ 划分为一个参数化区间,下一个区间划分则从 $i + \lambda^* + 1$ 开始判断。最后,结合参数化区间的曲线形态特征选择代表性参数。例如,图1(a)中曲线各段根据互信息大小可划分为两个参数化区间,由于曲线形态为直线,各区间可以采用一个采样点数据对曲线进行拟合,如第1个区间选择 s_1 ,第2个区间选择 s_6 。同样,由于图1(b)中曲线形态为斜线,各区间可以采用两个采样点数据对曲线进行拟合,如第1个区间选择 s_1 、 s_6 ,第2个区间选择 s_7 、 s_{12} 。图1(c)中曲线可划分为3个参数化区间,由于曲线形态为二次项型,第1、第3个区间只有两个采样点数据,因而,采用该区间所有采样点数据对该段曲线进行拟合;第2个区间可以采用3个采样点数据对曲线进行拟合,如选择 s_3 、 s_7 、 s_{12} 。

进一步,考虑到操作变量曲线离散化的各段对指标作用有正有负,因而在上述参数化结果的基础上,还需判断各区间不同部分对指标作用方向是否一致。对此,本文采用相关系数进行操作变量与指标变量间正负相关性判断,具体方法下:

$$\tilde{\rho}_i = \frac{\sum_{k=1}^K (\hat{m}_{ki} - \bar{m}_i)(y_k - \bar{y}_{1 \sim k})}{\sqrt{\sum_{k=1}^K (\hat{m}_{ki} - \bar{m}_i)^2 (y_k - \bar{y}_{1 \sim k})^2}}. \quad (5)$$

其中: $\tilde{\rho}_i$ 为第 k 个批次第 i 个时段变量 \hat{m}_{ki} 与指标变量间的相关系数, \bar{m}_i 为第 k 个批次第 i 个时段变量均值, $\bar{y}_{1 \sim k}$ 为 k 个批次指标变量均值。根据式(5),若划分为同一区间的操作变量与指标变量相关系数符号不一致,则按照时间先后顺序,在符号变化的采样时间点处进行二次划分,从而保证同一划分区间内的操作变量对指标变量的作用大小近似并且作用方向一致。最后,结合操作变量曲线的形态特征,选取代表性参数来描述二次划分的区间。

2 PLS建模

在数据驱动型间歇过程优化研究中,PLS算法常被用于建立操作变量与指标变量间的预测模型,本文也采用这一方法对间歇过程建模。

假定采集 J 个变量在 K 个采样点下的 L 批次构成的三维数据为 $\tilde{X}(L \times J \times K)$,沿着批次方向展开并进行标准化处理得到二维矩阵 $X = [S, X_m]$ 。其中: S 为 L 批次操作变量数据, X_m 为 L 批次过程测量变量数据。终点指标变量矩阵为 $y = (l \times 1)$,利用

偏最小二乘算法对批次数据 X 与指标变量 y 降维分解^[20], 有

$$\begin{aligned} X &= TP^T + L, \\ y &= TV^T + D. \end{aligned} \quad (6)$$

其中: $T = [t_1, t_2, \dots, t_{a^*}]$ 为得分矩阵(主元), a^* 为主元数, P 、 V 分别为 X 、 y 的载荷矩阵, L 、 D 为残差矩阵. 由于主元 t_1, t_2, \dots, t_{a^*} 可以表示成 x_1, x_2, \dots, x_{Ia} 的线性组合, 可得 y 关于 X 的偏最小二乘回归模型为

$$\begin{aligned} \hat{y} &= x_{\text{new}} \hat{b}, \\ \hat{b} &= \Gamma(P^T \Gamma)^{-1} D^T. \end{aligned} \quad (7)$$

其中: x_{new} 为新批次数据, \hat{y} 为新批次指标预测值, \hat{b} 为回归系数向量, Γ 为权重矩阵.

进一步, 考虑到随着时间的推移, 间歇过程的生产特性也会发生变化, 如果使用固定的偏最小二乘回归模型对指标进行预测, 则预测结果可能会与实际过程偏差越来越大, 影响优化效果. 为了解决这一问题, 本文采用 Dayal 等^[20] 提出的自适应偏最小二乘模型, 具体方法如下:

$$\begin{aligned} X_k &= \begin{bmatrix} \beta X_{k-1} \\ x_k \end{bmatrix} \quad \text{and} \quad y_{1 \sim k} = \begin{bmatrix} \beta y_{1 \sim k-1} \\ y_k \end{bmatrix}, \\ [y_{1 \sim k} | X_k] &\xrightarrow{\text{PLS}} \hat{b}_k. \end{aligned} \quad (8)$$

其中: X_k 为前 k 个批次数据; x_k 为第 k 个批次数据; β 为权重系数, 表示历史批次数据的重要性; $y_{1 \sim k-1}$ 为前 $k-1$ 个批次的指标变量; y_k 为第 k 个批次的指标变量; \hat{b}_k 为由前 k 个批次数据得到的新回归系数. 进而, 自适应偏最小二乘回归模型可以写为

$$\hat{y}_k = x_k \hat{b}_k. \quad (9)$$

3 批内修正优化算法

间歇性生产过程中的扰动往往影响最终的产品质量, 因而本文采用基于批次内修正的优化策略, 如图2所示. 根据过程的阶段特性, 设置决策点 $(\theta_0, \theta_1, \theta_2, \theta_3)$, 然后根据当前决策点上终点指标的预

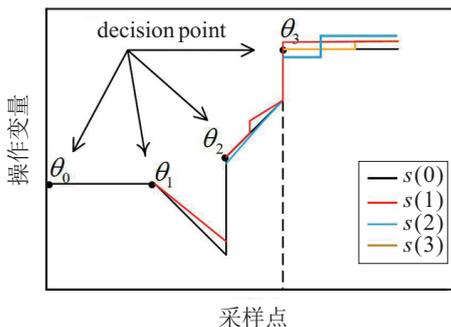


图2 批内修正优化策略示意

测值与期望值之间的偏差, 对决策点之后未实施的操作变量曲线进行调整, 从而可以得到新的操作变量曲线 $s(0)$ 、 $s(1)$ 、 $s(2)$ 、 $s(3)$, 以下将对该方法进行详细介绍.

假定第 k 批次预测终点指标变量 \hat{y}_k 与期望终点指标变量 y_d 间的偏差 \hat{e}_k ^[10] 为

$$\hat{e}_k = y_d - \hat{y}_k = y_d - x_k \hat{b}_k, \quad (10)$$

第 $k+1$ 批次预测终点指标变量 \hat{y}_{k+1} 与期望终点指标变量 y_d 间的偏差 \hat{e}_{k+1} ^[10] 为

$$\hat{e}_{k+1} = y_d - \hat{y}_{k+1} = y_d - x_{k+1} \hat{b}_{k+1}. \quad (11)$$

其中 x_{k+1} 包含两类数据: 决策点 $\theta_h (h=0, 1, \dots)$ 之前已知的操作变量数据和过程测量变量数据 $x_{k+1}^{\text{known}, (0:\theta_h)}$; 决策点 θ_h 之后未实施的操作变量数据和未知的过程测量变量数据 $x_{k+1}^{\text{feature}, (0:\theta_h)}$.

进一步, 根据式(10)和(11)可以得到^[10]

$$\hat{e}_{k+1} = \hat{e}_k - (x_{k+1} - x_k) \hat{b}_{k+1} = \hat{e}_k - \Delta x_{k+1} \hat{b}_{k+1}. \quad (12)$$

为了使预测指标最终收敛于期望值, 该优化问题可以写为如下形式:

$$\begin{aligned} \min & \hat{e}_{k+1} Q_1 \hat{e}_{k+1}^T + \Delta x_{k+1} Q_2 \Delta x_{k+1}^T; \\ \text{s.t.} & \begin{cases} \hat{y}_{k+1} = (x_k + \Delta x_{k+1}) \hat{b}_k, \\ x_{\min} \leq x_{k+1} \leq x_{\max}. \end{cases} \end{aligned} \quad (13)$$

其中: Q_1 、 Q_2 为权重矩阵, x_{\min} 、 x_{\max} 分别为 x_{k+1} 调整范围的上下界, Δx_{k+1} 为 x_{k+1} 的调整量. 上述优化问题可以简化为带约束的二次规划问题求解, 进而得到第 x_{k+1} 个批次变量(操作变量与测量变量)的调整量 Δx_{k+1} , 则第 $k+1$ 个批次优化的操作变量与过程测量变量为 $x_{k+1} = x_k + \Delta x_{k+1}$.

当 $h=0$ 时, 式(13)即为批次到批次优化策略, 当生产过程进行到 $h>0$ 时, 此时部分批次数据已知, 可根据该部分已知数据对尚未实施的操作变量数据进行调整, 具体方法如下.

若 $y_d - \hat{y}_{k+1, \theta_h} \leq \rho$, 则生产过程按照当前设定的操作变量曲线运行到下一个决策点, 其中阈值 ρ 的选择具有一定的启发性, 可以根据经验或操作要求设置. \hat{y}_{k+1, θ_h} 为生产过程到达第 θ_h 个决策点时终点指标的预测值, 由于该预测值的获得一般需要完整批次数据, 对于决策点之后未知数据, 本文采用基于 PCA 映射的预估方法对决策点 θ_h 之后未知的数据进行估计, 详细的方法可以参见文献[10].

若 $y_d - \hat{y}_{k+1, \theta_h} > \rho$, 则对决策点 θ_h 后的操作变量曲线进行调整. 为了使得调整后指标预测值与期

望值偏差尽可能减小,决策点后操作变量的调整量可以根据如下优化模型求解:

$$\begin{aligned} \min & \hat{e}'_{k+1,\theta_h} Q_1(\hat{e}'_{k+1,\theta_h})^T + \Delta x'_{k+1} Q_2(\Delta x'_{k+1})^T; \\ \text{s.t.} & \begin{cases} \hat{y}'_{k+1,\theta_h} = (\hat{x}_{k+1}^{\theta_{h-1}} + \Delta x'_{k+1}) \hat{b}_k, \\ x_{\min} \leq \hat{x}_{k+1}^{\theta_h} \leq x_{\max}. \end{cases} \end{aligned} \quad (14)$$

其中

$$\begin{aligned} \hat{e}'_{k+1,\theta_h} &= \hat{e}_{k+1,\theta_0} - (\hat{x}_{k+1}^{\theta_h} - \hat{x}_{k+1}^{\theta_{h-1}}) \hat{b}_k = \\ & \hat{e}'_{k+1,\theta_{h-1}} - \Delta x'_{k+1} \hat{b}_k, \\ \hat{e}_{k+1,\theta_h} &= y_d - \hat{y}'_{k+1,\theta_h}, \end{aligned}$$

\hat{e}'_{k+1,θ_h} 为当前工况下(决策点为 θ_h 时)指标预测值 \hat{y}'_{k+1,θ_h} 与期望值之差, $\hat{e}'_{k+1,\theta_{h-1}}$ 为第 $h-1$ 个决策点上得到的第 $k+1$ 批次指标预测值与期望值之差, $\hat{x}_{k+1}^{\theta_{h-1}}$ 为第 $h-1$ 个决策点上得到的第 $k+1$ 批次变量数据, $\Delta x'_{k+1}$ 为第 h 个决策点上计算的批次变量的调整量, $\hat{x}_{k+1}^{\theta_h}$ 为优化的新批次变量数据. 但是 $\Delta x'_{k+1}$ 中既包含了决策点后批次变量的调整量,也包含了对决策点之前已知部分的调整. 针对这一问题,本文提出如下补偿策略:

$$\begin{aligned} \min & \hat{e}_c Q_1(\hat{e}_c)^T + \\ & \Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} Q_{2,1}(\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})})^T; \\ \text{s.t.} & \begin{cases} \hat{y}_{k+1}^{\text{future},(\theta_h:\text{end})} = \Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} \hat{b}_k^{\text{future},(\theta_h:\text{end})}, \\ x_{\min}^{(\theta_h:\text{end})} - x_c \leq \Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} \leq x_{\max}^{(\theta_h:\text{end})} - x_c. \end{cases} \end{aligned} \quad (15)$$

其中

$$\begin{aligned} \hat{e}_c &= \Delta x_{k+1}^{\text{future},(0:\theta_h)} \hat{b}_k^{\text{future},(0:\theta_h)} - \\ & \Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} \hat{b}_k^{\text{future},(\theta_h:\text{end})}, \\ x_c &= \hat{x}_{k+1}^{(\theta_h:\text{end})}, \end{aligned}$$

$\Delta x_{k+1}^{\text{future},(0:\theta_h)}$ 是决策点 θ_h 之前的调整量, $\hat{b}_k^{\text{future},(0:\theta_h)}$ 是对应的回归系数,两者乘积即为待补偿量. 由于决策点 θ_h 之前的数据无法调整,本补偿策略采用决策点 θ_h 之后未实施数据对 $\Delta x_{k+1}^{\text{future},(0:\theta_h)}$ 这部分数据进行补偿. $\Delta x_{k+1}^{\text{future},(0:\theta_h)}$ 为 $\Delta x'_{k+1}$ 中决策点 θ_h 之前的调整量; $\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})}$ 为 $\Delta x'_{k+1}$ 中决策点 θ_h 之后的调整量; $\hat{b}_k^{\text{future},(\theta_h:\text{end})}$ 为 \hat{b}_k 中对应 $\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})}$ 的回归系数; $Q_{2,1}$ 为权重矩阵,用于限制 $\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})}$ 的调整幅度以避免过于激烈的变化; $\hat{y}_{k+1}^{\text{future},(\theta_h:\text{end})}$ 为决策点 θ_h 后调整量 $\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})}$ 与对应回归系数 $\hat{b}_k^{\text{future},(\theta_h:\text{end})}$ 的乘积; $x_{\min}^{(\theta_h:\text{end})}$ 为 x_{\min} 中决策点 θ_h 后的值, $x_{\max}^{(\theta_h:\text{end})}$ 为

x_{\max} 中决策点 θ_h 后的值; $\hat{x}_{k+1}^{(\theta_h:\text{end})}$ 为式(14)计算得到的 $\hat{x}_{k+1}^{\theta_h}$ 中决策点 θ_h 后的数据,即式(15)中调整量的求解范围为物理约束范围 (x_{\min}, x_{\max}) 与式(14)求得的新批次数据的差值.

根据式(14)和(15)可得决策点后批次变量的调整 $\Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} + \Delta \hat{x}_{k+1}^{(\theta_h:\text{end})}$,则根据下式可以得到决策点 θ_h 后优化的操作变量:

$$\hat{x}_{k+1,\theta_h} = \hat{x}_{k+1}^{\theta_{h-1},(\theta_h:\text{end})} + \Delta x_{k+1}^{\text{future},(\theta_h:\text{end})} + \Delta \hat{x}_{k+1}^{(\theta_h:\text{end})}. \quad (16)$$

其中: \hat{x}_{k+1,θ_h} 为决策点 θ_h 后优化的批次变量(包括操作变量和测量变量), $\hat{x}_{k+1}^{\theta_{h-1},(\theta_h:\text{end})}$ 为 $\hat{x}_{k+1}^{\theta_{h-1}}$ 决策点 θ_h 后的数据.

4 仿真实例

本文以间歇结晶过程为研究实例,采用实际工业生产中31批次正常工况下的温度操作变量数据、2个过程测量变量数据进行优化研究,各批次单位时间内产品产量作为指标. 整个生产过程共分为4个操作阶段,每批次的生产时间约为2h,产品产量只能在批次生产结束后获得,生产过程期望指标为24t/h. 先将采集的操作变量数据及过程测量变量数据进行数据预处理,再进行数据对齐.

将对齐的过程变量曲线分段离散化,其中分段时间间隔为1min. 操作变量曲线与测量变量曲线各划分为138个时段,对应地采用分段常数参数化方法表征一条曲线时则需要138个参数. 根据式(3)~(5)计算测量变量曲线各时段与指标变量之间的互信息相关系数.

结合式(5)和操作变量曲线的形态特征,选择代表性参数对操作变量曲线进行表征,选择结果如表1所示.

表1 基于互信息的操作变量曲线参数化

生产阶段	参数
预结晶阶段	$s_1, s_3, s_5, s_{10}, s_{12}, s_{14}, s_{15},$
$h_1 = 0.05$	$s_{16}, s_{18}, s_{33}, s_{34}, s_{35}$
降温结晶阶段	$s_{36}, s_{37}, s_{40}, s_{41}, s_{42}, s_{44}, s_{45},$
$h_2 = 0.073$	$s_{51}, s_{52}, s_{57}, s_{58}, s_{72}, s_{73}, s_{77}$
	s_{78}, s_{79}, s_{80}
升温发汗阶段	$s_{81}, s_{83}, s_{84}, s_{85}, s_{86}, s_{87}, s_{89}$
$h_3 = 0.1$	$s_{90}, s_{91}, s_{92}, s_{93}, s_{94}, s_{95}, s_{96}$
	$s_{97}, s_{98}, s_{99}, s_{102}, s_{103}, s_{104}$
全熔融阶段	$s_{105}, s_{107}, s_{115}, s_{116}, s_{119}, s_{120}$
$h_4 = 0.04$	$s_{124}, s_{127}, s_{128}, s_{129}, s_{130}, s_{131}$
	$s_{132}, s_{133}, s_{136}$

从表1中可以看出,相比于阶跃分段常数参数化方法^[16]下需要调整138个操作变量曲线参数,本文参数化方法仅选择其中64个参数用于优化,大大降低了优化运算的复杂度.

进一步,为了验证所提出参数化方法的有效性,将两种参数化方法应用于本文优化方法,结晶过程产品产量的优化结果如图3所示.

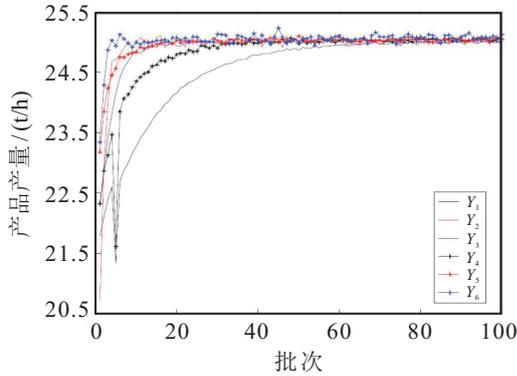


图3 两种参数化方法的产品产量预测值

图3中曲线 Y_1 、 Y_2 、 Y_3 对应于分段常数参数化方法下决策点数分别为0、1、2时优化方法对应的产品产量预测值,曲线 Y_4 、 Y_5 、 Y_6 对应于本文参数化方法下决策点数分别为0、1、2时优化方法对应的产品产量预测值.比较两组参数化方法下的指标迭代优化曲线可以看出,本文参数化方法使得优化算法的收敛速度更快,由此验证了本文参数化方法在间歇过程优化中的有效性.

另外,为了检验所提出优化方法的有效性,将文献[10]中优化方法与本文优化方法进行比较,在仿真中的第5个批次施加10%的扰动,该扰动持续到本批次结束.可以看出,相比于文献[10]中批次到批次的优化方法,本文所提出批次内修正的优化方法能明显减弱扰动对优化效果的影响,由此验证了本文优化方法的有效性.同一参数化方法下优化操作变量曲线如图4和图5所示.

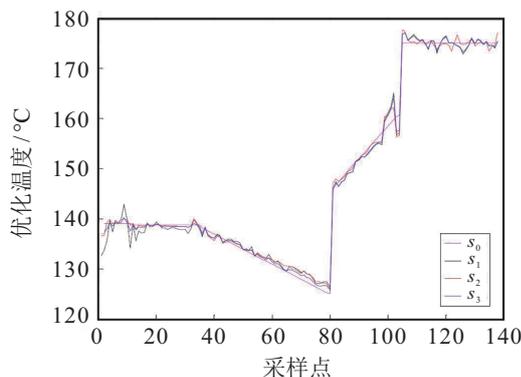


图4 分段常数参数化方法下优化的操作变量曲线

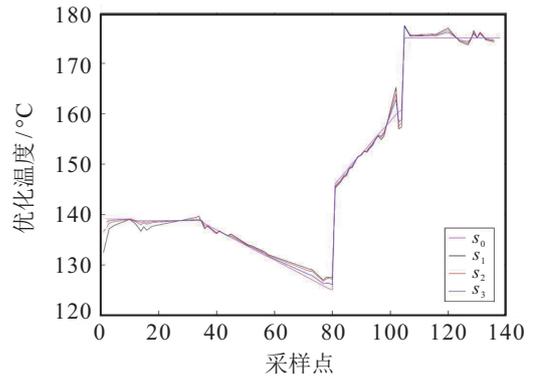


图5 本文参数化方法下优化的操作变量曲线

对比图4与图5两种参数化方法下优化的操作变量曲线可以看出,本文参数化方法下获得的优化操作变量曲线更为平滑,这也更便于在实际工业生产中的实施.

综上,相比于采用分段离散化方法的优化策略,本文所提出的参数化方法使得优化模型所需调整参数更少,优化收敛速度更快,优化的操作变量曲线更为平滑,本文参数化方法表现出了更好的优化性能;相比于批次到批次的优化方法,本文所提出的批内修正优化方法能够明显减弱扰动对最终优化效果的影响,由此验证了本文方法的有效性.

5 结论

本文针对间歇过程批次内噪声干扰与优化模型中参数过多会影响优化效果问题,提出了一种基于互信息操作变量曲线参数化的间歇过程批内修正优化新策略:1)采用互信息与相关系数对操作变量曲线进行参数化处理,选取有代表性参数对曲线进行表征,仿真结果表明,本文参数化方法在减少优化模型中待调参数数量的同时,提高了优化收敛速度;2)当批次内存在明显扰动时,仿真结果表明,所提出带约束的间歇过程批次内修正优化方法能够根据生产过程中的信息对未实施的操作变量曲线进行调整,从而减弱批次内扰动对最终优化效果的影响,由此验证了本文方法的有效性.

参考文献(References)

[1] 史洪岩,苑明哲,王天然,等. 间歇过程动态优化方法综述[J]. 信息与控制, 2012, 41(1): 75-82.
(Shi H Y, Yuan M Z, Wang T R, et al. A survey on dynamic optimization methods of batch processes[J]. Information and Control, 2012, 41(1): 75-82.)

[2] 赵春晖,王福利,姚远,等. 基于时段的间歇过程统计建模、在线监测及质量预报[J]. 自动化学报, 2010, 36(3): 366-374.
(Zhao C H, Wang F L, Yao Y, et al. Phase-based statistical modeling, online monitoring and quality prediction for

- batch processes[J]. *Acta Automatica Sinica*, 2010, 36(3): 366-374.)
- [3] Corbett B, Mhaskar P. Data-driven modeling and quality control of variable duration batch processes with discrete inputs[J]. *Industrial & Engineering Chemistry Research*, 2017, 56(24): 6962-6980.
- [4] Bonvin D, Srinivasan B. Control and optimization of batch processes[J]. *IEEE Control Systems Magazine*, 2006, 26(6): 34-45.
- [5] Flores-Cerrillo J, MacGregor J F. Control of batch product quality by trajectory manipulation using latent variable models[J]. *Journal of Process Control*, 2004, 14(5): 539-553.
- [6] Srinivasan B, Palanki S, Bonvin D. Dynamic optimization of batch processes I: Characterization of the nominal solution[J]. *Computers & Chemical Engineering*, 2003, 27(5): 759-760.
- [7] 仇力, 栾小丽, 刘飞. 基于主元相似度的间歇过程操作曲线递推优化[J]. *化工学报*, 2017, 68(7): 2859-2865. (Qiu L, Luan X L, Liu F. A recursive optimization method for batch process trajectories based on similarity of principal components[J]. *Journal of Chemical Industry and Engineering: China*, 2017, 68(7): 2859-2865.)
- [8] 魏华彤. 基于数据驱动的间歇过程监控方法研究[D]. 北京: 北京化工大学信息科学与技术学院, 2013. (Wei H T. Research on data-driven intermittent process monitoring method[D]. Beijing: School of Information Science and Technology, Beijing University of Chemical Technology, 2013.)
- [9] Fiordalis A, Georgakis C. Data-driven, using design of dynamic experiments, versus model-driven optimization of batch crystallization processes[J]. *Journal of Process Control*, 2013, 23(2): 179-188.
- [10] 邸丽清, 熊智华, 阳宪惠. 基于MPLS的间歇过程终点质量迭代优化控制[J]. *化工自动化及仪表*, 2007, 34(2): 10-12. (Di L Q, Xiong Z H, Yang X H. MPLS-based batch process endpoint quality iterative optimization control[J]. *Control and Instruments in Chemical Industry*, 2007, 34(2): 10-12.)
- [11] 黄碧璇, 毛志忠, 贾润达. 草酸钴合成过程批次间自适应优化[J]. *控制理论与应用*, 2016, 33(2): 189-195. (Huang B X, Mao Z Z, Jia R D. A batch-to-batch adaptive optimization for the cobalt oxalate synthesis process[J]. *Control Theory & Applications*, 2016, 33(2): 189-195.)
- [12] Li C F, Zhang J, Wang G Z. Batch-to-batch optimal control of batch processes based on recursively updated nonlinear partial least squares models[J]. *Chemical Engineering Communications*, 2007, 194(3): 261-279.
- [13] 贾润达, 毛志忠, 王福利. 基于KPLS模型的间歇过程产品质量控制[J]. *化工学报*, 2013, 64(4): 1332-1339. (Jia R D, Mao Z Z, Wang F L. KPLS model based product quality control for batch processes[J]. *Journal of Chemical Industry and Engineering: China*, 2013, 64(4): 1332-1339.)
- [14] Jia R D, Mao Z Z, Wang F L, et al. Sequential and orthogonalized partial least-squares model based real-time final quality control strategy for batch processes[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(19): 5654-5669.
- [15] 叶凌霄, 马修水, 宋执环. 基于输入轨迹参数化的间歇过程迭代学习控制[J]. *化工学报*, 2016, 67(3): 743-750. (Ye L J, Ma X S, Song Z H. Iterative learning control of batch process with input trajectory parameterization[J]. *Journal of Chemical Industry and Engineering: China*, 2016, 67(3): 743-750.)
- [16] 孔祥松. 快速、低成本间歇过程无模型优化方法研究[D]. 杭州: 浙江大学控制科学与工程学院, 2011. (Kong X S. Research on model-free optimization method for fast and low-cost intermittent processes[D]. Hangzhou: College of Control Science and Engineering, Zhejiang University, 2011.)
- [17] Rossi F, Lendasse A, François D, et al. Mutual information for the selection of relevant variables in spectrometric nonlinear modelling[J]. *Chemometrics and Intelligent Laboratory Systems*, 2006, 80(2): 215-226.
- [18] Shannon C E. Communication theory of secrecy systems[J]. *Bell System Technical Journal*, 1949, 28(4): 656-715.
- [19] 夏源. 基于信息熵的软测量问题研究[D]. 无锡: 江南大学物联网工程学院, 2015. (Xia Y. Research on soft measurement based on information entropy[D]. Wuxi: School of Internet of Things Engineering, Jiangnan University, 2015.)
- [20] Dayal B S, MacGregor J F. Improved PLS algorithms[J]. *Journal of Chemometrics*, 1997, 11(1): 73-85.

作者简介

栾小丽(1979—), 女, 教授, 博士生导师, 从事过程控制与优化等研究, E-mail: xlluan@jiangnan.edu.cn;

刘晓凤(1993—), 女, 硕士生, 从事间歇过程优化的研究, E-mail: lxfjiangna@163.com;

刘飞(1965—), 男, 教授, 博士生导师, 从事过程控制等研究, E-mail: fliu@jiangnan.edu.cn.

(责任编辑: 李君玲)