

自适应密集预测的模型算法控制

金元郁

顾兴源

(抚顺石油学院自动化所, 辽宁)

(东北工学院自动控制系统, 沈阳)

摘要: 本文中提出了一种新的预测控制策略: 在一个模型采样周期内(本文中定义)进行数次预测控制。

关键词: 预测控制; 模型算法控制

1 引言

在基于脉冲响应模型的预测控制算法中, 随着采样周期的减小, 增加模型参数的个数是必要的^[1~3]。但若采用自适应控制策略, 则因涉及在线辨识, 采样周期不能取得过小, 因此不能及时调整预测值和控制输入量。为此本文中提出: 将原来的采样周期(定义为模型周期 T_m)划分为几个小周期(定义为控制周期 T_c), 使滚动优化控制以小周期进行, 采用密集预测控制之策略。

2 一种密集预测的方法

本文中采用的脉冲响应模型为

$$y_m(k) = \sum_{i=1}^n h(i)w(k-i). \quad (2.1)$$

其中 $y_m(k)$, $h(i)$ 和 k 分别表示模型输出, 脉冲响应和离散时间, 定义 $w(k)$ 为模型输入。另外定义 $u(k)$ 为控制输入。

传统的预测控制和本文中提出的密集预测控制方法分别表示在图1和图2中。其中 $y_r(t)$ 、 $y_p(t)$ 、 $w(t)$ 和 $u(t)$ 分别表示参考轨迹、预测输出、模型输入和控制输入。

图1中控制输入 $u(t)$ 和控制采样周期 T_c 分别相等于模型输入 $w(t)$ 和模型采样周期 T_m 。图2中输出预测分为两部分: 一部分取决于未来的输入量, 这与原算法相同, 另一部分涉及到过去的输入量, 这与原算法不同: 原算法中控制量在一个模型采样周期 T_m 内不变, 而现在变化多次, 预测和控制计算及采样输出和实际控制是以控制周期 T_c 为间隔进行的, 若搞自适应则其辨识计算也是以控制周期 T_c 为间隔进行的。但将来的输出预测值的时间间隔是模型周期 T_m , 其预测计算式是由式(2.1)推导出来的, 用来辨识的模型也是式(2.1)。因此需要从实际控制输入 $u(t)$ 到模型输入 $w(t)$ 的换算公式, 下面给出两种换算公式。

图2中设模型采样周期 T_m 和控制采样周期 T_c 之间的关系为 $T_m = Q \cdot T_c$, 其中 Q 为大于1的正整数。若设脉冲响应序列值在一个模型采样周期内是不变化的, 则有

$$w(k-i) = \frac{1}{Q} \sum_{j=1}^Q u(k-(i-1)Q-j), \quad i=1,2,3,\dots \quad (2.2)$$

若设脉冲响应序列值在一个模型采样周期内是线性增加(或减小)的,而在每个控制采样周期内保持不变,即用阶梯型近似脉冲响应曲线,可得

$$w(k-i) = \sum_{j=1}^Q \frac{j}{Q^2} u(k-(i-1)Q-j) + \sum_{j=1}^{Q-1} \frac{Q-j}{Q^2} u(k-iQ-j), \quad i=1,2,\dots,n-1 \quad (2.3)$$

$$w(k-n) = \sum_{j=1}^Q \frac{j}{Q^2} u(k-(n-1)Q-j). \quad (2.4)$$

这是利用区间端点的已知信息,对区间内插值的方法获得的一种计算公式,比起前一种算法可提高其模型精度。




图 1 在 k 和 $k+1$ 时刻的传统的预测控制计算




图 2 在 k 和 $k+1$ 时刻的密集预测控制计算

3 算法的提出

在将来的模型输入恒等于 $w(k-1)$ 的假设条件下,由式(2.1)可得如下的一种输出预测值的计算公式.

$$y_m^* = \begin{bmatrix} y_m^*(k+1) \\ y_m^*(k+2) \\ \vdots \\ y_m^*(k+p) \end{bmatrix} = \begin{bmatrix} w(k-1) & w(k-1) & w(k-2) & w(k-3) & \cdots & w(k-n+1) \\ w(k-1) & w(k-1) & w(k-1) & w(k-2) & \cdots & w(k-n+2) \\ \vdots & & \vdots & & & \vdots \\ w(k-1) & w(k-1) & w(k-1) & w(k-1) & \cdots & w(k-n+p) \end{bmatrix} \begin{bmatrix} h(1) \\ h(2) \\ \vdots \\ h(n) \end{bmatrix} \quad (3.1)$$

由式(2.1)和(3.1),得

$$y_m = \begin{bmatrix} y_m(k+1) \\ y_m(k+2) \\ \vdots \\ y_m(k+p) \end{bmatrix} = y_m^* + H\Delta w. \quad (3.2)$$

其中, $H = \begin{bmatrix} h(1) & 0 & \cdots & 0 \\ h(2) & h(1) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ h(p) & h(p-1) & \cdots & h(1) \end{bmatrix},$

$$\Delta w = (\Delta w(k) \Delta w(k+1) \cdots \Delta w(k+p-1))^T,$$

$$\Delta w(k-1+i) = w(k-1+i) - w(k-1), \quad i = 1, 2, 3, \dots, p.$$

参考轨迹 $y_r(t)$ 的计算式为

$$y_r(k) = y(k),$$

$$y_r(k+i) = \alpha y_r(k+i-1) + (1-\alpha)s, \quad i = 1, 2, 3, \dots, p. \quad (3.3)$$

其中 s 是给定值, α 是柔化系数, $\alpha = e^{-\tau/T_m}$, T_m 是模型采样周期, τ 是时间常数.

设定二次性能指标为

$$J = (y_m - y_r)^T (y_m - y_r) + \beta^2 \Delta w^T \Delta w \quad (3.4)$$

其中 y_r 是参考轨迹向量: $y_r = (y_r(k+1) y_r(k+2) \cdots y_r(k+p))^T$, β^2 是模型输入增量的加权项.

极小化二次性能指标 J , 我们可获得, 式(3.4)中的 Δw 的最优解.

$$\Delta w = (H^T H + \beta^2 I)^{-1} H^T (y_r - y_m^*). \quad (3.5)$$

在 k 时刻, 令控制输入 $u(k)$ 相等于模型输入 $w(k)$, 则有:

$$u(k) = w(k) = w(k-1) + \Delta w(k). \quad (3.6)$$

其中 $\Delta w(k)$ 是式(3.5)中的向量 Δw 的第一个元素. 在下一个控制采样周期, 重新计算出新的控制输入.

总之, 在每一个控制采样周期, 需完成如下的计算步骤.

1) 用式(2.3)和(2.4), 计算过去的模型输入 $w(t)$.

- 2) 在线辨识式(2.1)中的脉冲响应序列值 $h(i)$.
- 3) 用式(3.1)~(3.6)计算控制输入 $u(k)$.
- 4) 移动各个向量的数据,为下一个周期的计算做准备.

仿真例子

设给定值 s 为

$$s = \begin{cases} 100 & \text{当 } 0 \leq t < 100 \text{ 分} \\ 200 & \text{当 } 100 \text{ 分} \leq t \leq 250 \text{ 分} \end{cases}$$

设被控对象的传递函数为(时间单位为分)

$$\frac{100e^{-ms}}{100s^2 + 10s + 1}, \text{ 其中 } m = \begin{cases} 0 & \text{当 } 0 \leq t < 100 \text{ 分, 即 } s = 100, \\ 4 & \text{当 } 100 \text{ 分} \leq t \leq 250 \text{ 分, 即 } s = 200. \end{cases}$$

上述的传递函数的时滞随着设定值的改变而变化是有实际背景的. 举例说, 在某一电加热炉的控制中, 若在不同的温度给定值下进行控制, 则其参数包括时滞也有一些变化.

图3和图4中分别表示了柔化系数 α 取不同值时的自适应密集预测的模型算法控制(AIPMAC)结果. 其控制参数选为: 模型采样周期 $T_m = 5$ 分; 控制采样周期 $T_c = T_m/10$; 脉冲响应序列个数 $n = 20$; 预测长度 $p = 3$; 加权项 $\beta^2 = 5$; 递推最小二乘法辨识算法中的遗忘因子 $\lambda = 0.98$.

在图5和图6中, 给出了自适应模型算法控制(AMAC)的结果, 此时选 $T_c = T_m = 5$ 分钟, 其它的参数分别相等于图3和图4中的控制参数.

从仿真结果知, AIPMAC 比 AMAC, 控制质量都得到不同程度的改善, 两种控制算法每次用于辨识的计算量相同, 但它们的计算周期不同.

如果本例中的 AMAC 的控制采样周期 T_c (等于模型采样周期 T_m) 也选为 0.5 分, 即相等于本例中的 AIPMAC 中的 T_c , 则模型参数的个数需增大到 200 个左右, 实际上用递推二乘法在线辨识如此多的参数是不可行的. 而且其离散模型的时滞变化的范围将达到 8 个采样周期 ($T_c = T_m = 0.5$ 分, $8 \times T_m =$ 时滞变化的范围 = 4 分).




图3 $\alpha=0$ 时的 AIPMAC 结果




图4 $\alpha=0.5$ 时的 AIPMAC 结果





图5 $\alpha=0$ 时的 AMAC 结果

此时若预测长度 p 小于 8 (本例中 $p=3$), 则不可能进行有效的控制, 即使增加预测长度, 其控制效果也会受到时滞变化的影响。

在传统的预测控制中, 由于两个靠近的预测点之间的时间间隔是一个采样周期, 所以在预测长度 p 相同的条件下, 其预测

的覆盖时间范围随采样周期的减小而减小, 即其预测的输出越来越局限在局部的时间范围, 显然这对于提高预测的信息度是不利的。而增加预测长度, 式 (3.5) 中求逆矩阵的运算量按指数规律增加。尽管可以在一定假设条件下减小 H 阵的列数来达到减少计算量之目的, 但其代价是影响控制效果。另一方面, 若采样周期大, 则其滚动优化效果受到影响。密集预测控制的方法较好地解决了上述矛盾。仿真结果进一步验证了 AIPMAC 的有效性和实用性。

5 结 语

本文中提出的密集预测控制方法可以方便地推广到基于脉冲响应模型的其它控制算法中, 也可以推广到其它的控制算法中^[4,5]。




图 6 $\alpha=0.5$ 时的 AMAC 结果

参 考 文 献

- [1] Rouhani, R., Mehra, R. K. . Model Algorithm Control (MAC) Basic Theoretical Properties. Automatica, 1982, 18(4): 401—404
- [2] Cutler, C. R. . Dynamic Matrix Control—A Computer Control Algorithm, Proceedings of the 1980, JACC 1, WP5—B
- [3] Bruijn, P. M. . Model Algorithmic Control Using Impulse-response Models, Journal A, 1984, 25(2): 69—74
- [4] Clarke, D. W. , et al. Generalized Predictive Control—part 1. The Basic Algorithm. Automatica, 1987, 23(2): 137—148
- [5] De Keyser, R. M. C. , et al. A Comparative Study of Self-adaptive Long-range Predictive Control Methods. Automatica, 1988, 24(2): 149—163

Adaptive Intensive Predictive-Model Algorithm Control

Jin Yuanyu

(Research Centre of Automation, Fushun Petroleum Institute)

Gu Xingyuan

(Department of Automatic Control, Northeast University of Technology, Shenyang)

Abstract: In this paper we proposed a new control idea and strategy for predictive control; predictive control is implemented several times in one model sampling period defined in this paper.

Key words: predictive control; model algorithmic control