

文章编号: 1001-0920(2002)04-0407-04

基于在线优化的切换多模型自适应控制

刘鲁源, 吕伟杰, 牟世忠

(天津大学 自动化与能源工程学院, 天津 300072)

摘要: 介绍了切换多模型控制方法。针对多模型方法中子模型数量过多的问题, 提出一种基于模型集在线优化方案的多模型自适应控制算法, 并对其实时性进行讨论。该方法能减少子模型数量, 降低计算复杂度, 缩短系统的采样间隔。计算机仿真结果表明, 该方法在控制精度、计算复杂度等方面均优于采用固定模型集的切换方案。

关键词: 多模型; 自适应控制; 在线优化

中图分类号: TP 273 **文献标识码:** A

Switching multiple model adaptive control based on online optimization

LIU Lu-yuan, LU Wei-jie, MOU Shi-zhong

(College of Electrical Automation and Energy Engineering, Tianjin University, Tianjin 300072, China)

Abstract: A switching multiple model (SMM) control strategy is introduced. Focus on the question of many sub-models in traditional SMM, a SMM adaptive control based on online optimization method of model set is proposed. This strategy can reduce the number of sub-models and the computational load. It can reduce the sample interval. Simulation results have confirmed that the control accuracy, response speed and the computational simplicity of the proposed algorithm are super than SMM based on fixed model set.

Key words: multiple model; adaptive control; online optimization

1 引言

传统的自适应控制对于时不变和慢时变系统能进行很好的控制, 但由于实际系统存在复杂性、非线性、时变性、不确定性和不完全性, 使得自适应控制难以应用。为此, 早在 20 世纪 70 年代就有人提出了多模型控制^[1], 90 年代初又提出了切换式多模型控制^[2]。切换多模型控制方法的模型集多采用固定模型, 在对被控对象知之甚少或参数分布区域分散的

情况下, 为了达到较高的控制精度, 必须使用大量的子模型。子模型数量过多产生的直接后果是计算负担过重, 对硬件设备的要求迅速提高, 同时也限制了采样周期的减小, 从而影响了控制精度。

本文介绍了切换多模型方法, 并针对存在的问题提出一种基于在线优化的 SMM 方案。该方法能减少子模型的数量, 降低计算复杂度, 提高系统的控制精度。

收稿日期: 2001-06-08; 修回日期: 2001-08-31

作者简介: 刘鲁源(1941—), 男, 山东青岛人, 教授, 博士生导师, 从事运动控制理论及技术等研究; 吕伟杰(1975—), 女, 河北石家庄人, 博士生, 从事多模型自适应控制、小波神经网络等研究。

2 切换式多模型方法

2.1 模型结构

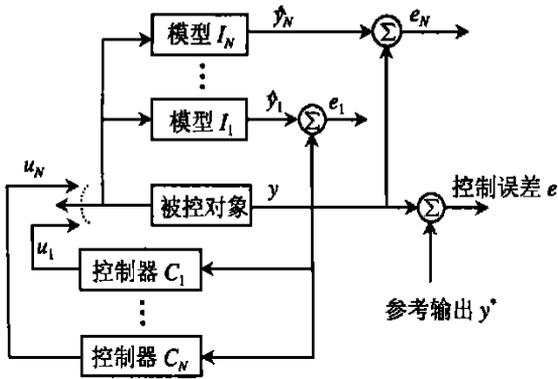


图 1 切换式多模型系统

SMM 控制系统结构如图 1 所示, 被控对象参数化为如下 ARMAX 模型形式

$$y(t) = \hat{\mathcal{L}}(t-1)\hat{H} \quad (1)$$

子模型参数化为下列形式

$$y_i(t) = \hat{\mathcal{L}}(t-1)H \quad (2)$$

其中, \hat{H} 和 H 分别为被控对象和第 i 个子模型的性能向量, $y(t)$ 和 $y_i(t)$ 分别为被控对象和第 i 个子模型的输出, $\hat{\mathcal{L}}(t-1) = [y(t-1), \dots, y(t-n_1), u(t-1), \dots, u(t-m_1)]$ 为回归向量, n_1 为回归向量 $\hat{\mathcal{L}}(t-1)$ 输出采样个数, m_1 为回归向量 $\hat{\mathcal{L}}(t-1)$ 输入采样个数。

2.2 控制器结构

由控制理论知, 各个子模型控制器的输出一般可写成如下形式

$$u_i(t) = \hat{X}(t)p_i \quad (3)$$

其中, $\hat{X}(t) \in \mathbb{R}^{2n}$ 是由 r, u 和 y 滤波产生的回归向量, 由所有控制器共享; p_i 为控制器 C_i 对理想控制器参数的估计。

2.3 切换方案

切换根据性能指标 $J_i(t)$ 来进行, 性能指标是由每个模型 I_i 的辨识误差 $e_i = y(t) - y_i(t)$ 而形成的, 并根据性能指标的最小值转换到相应的控制器。这一方法的合理性在于小的辨识误差引起小的跟踪误差。性能指标形式如下

$$J_i(t) = A e^2(t) + B \int_0^{K(t-S)} e^2(S) dS \quad (4)$$

其中 $A \geq 0, B > 0, K > 0$ 为自定义参数, A 和 B 决定暂态测量和长期测量在性能指标中的相对重要性, 遗忘因子 K 决定性能指标的遗忘长度。

为了避免任意快速切换现象, Middleton 等人^[3]

引入了滞后切换算法。设在 t 时刻采用偶对 (I_j, C_j) , $J_k(t) = \min\{J_i(t)\}$, 即 $J_j(t)$ 不是最小值。若 $J_j(t) \leq J_k(t) + D$ 则仍采用 (I_j, C_j) ; 若 $J_j(t) > J_k(t) + D$ 则控制切换到偶对 (I_k, C_k) 。其中 $D > 0$ 为滞后因子。

3 基于在线优化的切换多模型方法

在提出模型集在线优化方法之前, 首先引入如下定理:

定理 1 被控对象参数 $\hat{H} \in S \subset \mathbb{R}^{n_1+m_1}$, S 是对 \hat{H} 的初始估计。对 S 进行均匀离散化, 得到多模型 $H(i=1, 2, \dots, N)$ 。在某时刻 t , 将诸 H 按其性能指标 $J_i(t)$ 从小到大的顺序排成一列 $H_k(i=1, 2, \dots, K)$, 它们均为 S 的内点, 且 $J_{m_{k+1}}(t) > J_{m_k}(t)$ 。令 $J_{m_k}(t) = b$, 将 $\{H_i, i=1, 2, \dots, K\}$ 在 x_j 轴上投影的最大值和最小值记为 $x_{j\max}$ 和 $x_{j\min}$, 由 $[x_{j\max}, x_{j\min}]$ ($j=1, 2, \dots, k$) 约束形成的规则长方体记为 δ_r , 由 H_k 经凸组合形成的凸区域

$$\delta_m = \left\{ H \mid H = \sum_{i=1}^k A H_i, A \geq 0, \sum_{i=1}^k A = 1 \right\} \quad (5)$$

如果存在一个规则长方体 R , 它在任一 x_j 轴上的投影长度为 l_j , 且 $R \subset \delta_m$, 则 $\hat{H} \in \delta_m \subset \delta_r$ 。

3.1 模型集的在线优化

在有关多模型的文献中, 早期均采用固定模型集, 后来在此基础上加入一个自适应模型, 这样虽然可以在线调整自适应模型参数, 但子模型的数量仍然固定不变。多模型方法的一个先天问题是子模型的数量过多。假设系统 \hat{H} 有 3 个参数 $(a_1, a_2, a_3)^T$, 且估计区域为 $a_i \in [\underline{a}_i, \bar{a}_i], i=1, 2, 3$, 若对每个参数区间取 10 个采样值, 则共需 $10 \times 10 \times 10 = 1000$ 个子模型。可见即使在维数不高的情况下, 仍会遇到子模型数量过多的问题, 高维时这一问题将会更加严重。为此, 本文提出一种模型集在线优化的方法。

设初始得到被控对象 \hat{H} 的一个较粗糙的估计 S_0 , 对 S_0 进行离散化, 得到多模型 $\{H^0, i=1, 2, \dots, N_0\}$ (其中上标表示对应 S_0 的模型集), 共有 N_0 个模型投入系统运行。设在某一时刻 t , 将 H 按 $J_i(t)$ 从小到大的顺序排成一列, 得到 $\{H_k^0, i=1, 2, \dots, N_0\}$, 取前 K 个并保证这 K 个均为 S_0 的内点。当这 K 个子模型满足定理 1 条件时, 由该定理可知得到比 S_0 更小的区域 S_1 , 使得 $\hat{H} \in S_1$, 其中 S_1 可以是定理中的 δ_m 或 δ_r 。对 S_1 进行离散化, 得到另一组多模型 $\{H^1, i=1, 2, \dots, N_1\}$, 以此代替前一组多模型 $\{H^0, i=1, 2, \dots, N_0\}$ 。

$1, 2, \dots, N_0\}$ 投入系统运行, 并依新一组多模型重新设计控制器集。显然, 新一组多模型的分布密度比原多模型的分布密度大得多, 因此可以得到更佳的估计及控制性能。将这一过程迭代下去, 可以得到估计区域序列 S_2, S_3, \dots , 直到估计区域 S_k 充分小。此时得到的模型集 $\{H^k\}, i = 1, 2, \dots, N_k\}$ 已充分细密, 该过程可以终止。由此可得到满意的估计控制精度。

上述方案在不确定时不变系统中获得了优良的性能。当系统 H 慢时变时, 可以适当移动当前估计区域 S_k , 即移动当前模型集。移动规则是: 如果当前估计值远离 S_k 中心, 则将区域 S_k 的中心平移到 \hat{H} 位置。注意: 每次子模型的位置变化完毕, 无论是在线优化操作还是平移操作, 都应将各子模型的误差历史数据重新置为 0, 否则在一定时段内其性能指标不能写成式(4)形式, 且不能反映该子模型与对象真值的距离。正是由于这一原因, 这种平移操作不能太频繁。

3.2 在线优化算法

综上所述, 针对不确定时不变 / 慢时变系统, 可有如下在线优化算法:

1) 对被控对象参数 H 的初始估计 S_0 进行离散化, 得到多模型 $\{H^0\}, i = 1, 2, \dots, N_0\}$ 及对应控制器集 $\{C^0\}, i = 1, 2, \dots, N_0\}$ 投入系统运行。令采样时刻 $t = 0$, 区域索引 $k = 0$, 初始化当选模型。

2) 在 t 时刻, 根据当选模型及对应控制器计算当前时刻反馈输入, 并计算各子模型的输出及性能指标, 按滞后切换算法产生当前当选的子模型及当前对象估计参数 $\hat{H}(t)$ 。

3) 如果 $\hat{H}(t)$ 远离 S_k 的中心, 则将 S_k 平移到 $\hat{H}(t)$ 的位置。

4) 如果 S_k 已充分小或 $\{H^k\}, i = 1, 2, \dots, N_k\}$ 已充分密集, 则停止在线优化; 否则, 依据定理 1 估计出 \hat{H} 所在的一个更小的区域 $S_{k+1} < S_k$, 并对 S_{k+1} 进行离散化, 得到多模型 $\{H^{k+1}\}, i = 1, 2, \dots, N_{k+1}\}$ 及对应控制器集 $\{C^{k+1}\}, i = 1, 2, \dots, N_{k+1}\}$, 以此代替原模型集及控制器集投入系统运行。令 $k = k + 1$, 重置当选模型。

5) 令 $t = t + 1$, 转 2)。

3.3 算法复杂度及实时性分析

SMM 方法的计算并不复杂。设有 N 个子模型, 每一采样时刻需计算每个子模型的输入、输出偏差及性能指标; 取性能指标的最小值并进行切换, 计算当选模型对应控制器的输出。假如每个子模型均适

为 ARMAX 形式, 每个子模型有 m 个参数, 性能指标的误差记忆长度为 L , 则共需约 $(mN + NL + N \log_2 N)$ 次乘法操作(这里将比较运算及交换操作折合为乘法运算), 与 N 成拟线性关系。

以上是对基本 SMM 方法的算法时间分析。考虑带有模型集在线优化的 SMM, S_k 的平移操作将增加约 mN 次乘法运算; 当需要在线优化时, 可确定一个满足定理 1 条件的区域 δ_m 或 δ_r , 其乘法运算次数与 N 无关。对于产生一组新的多模型的过程, 在一定条件下可用简单的线性映射实现, 共需约 mN 次乘法运算; 在使用极点配置控制器情况下, 对 N 个控制器重新设计需约 m^2N 次乘法运算, 而在执行优化的采样周期, 约为 $(2m + m^2 + L + \log_2 N)N$ 次乘法运算, 可见与基本 SMM 相比增长并不剧烈。

由以上分析可见, SMM 运算复杂度与 N 成近似线性关系, 当 N 值很大时, 这种运算是惊人的。因而, 通过在线优化来降低 N 值, 从而降低运算复杂度并提高实时性便显得非常必要。随着微处理器及 VLSI 技术的飞速发展, 特别是数字信号处理 DSP(可达 10 亿次浮点运算 / 秒) 性价比的迅速提高, 为实际中采用高级而复杂的控制策略提供了物质基础。

4 仿真实验

仿真的二阶系统 ARMAX 模型为

$$y(t) = a_1 y(t-1) + a_2 y(t-2) + b_1 u(t-1) + b_2 u(t-2)$$

参数 $[a_1, a_2, b_1, b_2]^T = [1.5, -0.7, 1.0, 0.5]^T$; 在不确定空间 S_0 内, $a_1 \in [0, 3.5]$, $a_2 \in [-1.7, 0.3]$, $b_1 \in [-0.5, 2.0]$, $b_2 \in [0, 2.0]$; 参考输入信号 $r(t) = 8.0 \sin(t/30.0)$; 初始化多模型及控制器, 将 a_1, a_2, b_1, b_2 的不确定区域分别均匀分割成 5 份, 得到 6 个离散值, 共组合出 $6 \times 6 \times 6 \times 6 = 1296$ 个固定模型, 对应 1296 个极点配置控制器; 极点配置在 $Z_1 = 0.2, Z_2 = 0.5, Z_3 = -0.1$ 的位置, 无自适应模型; 指标函数

$$J_i(t) = A_i^2(t) + B \int_0^t e^{-\lambda(t-s)} e^2(s) ds$$

控制方案 1: 仅采用固定模型集滞后切换方案, 滞后因子 $h = 0.02$ 。系统输出响应如图 2 所示, 对应的参数估计序列如图 3 所示。

控制方案 2: 采用滞后切换方案及模型集在线

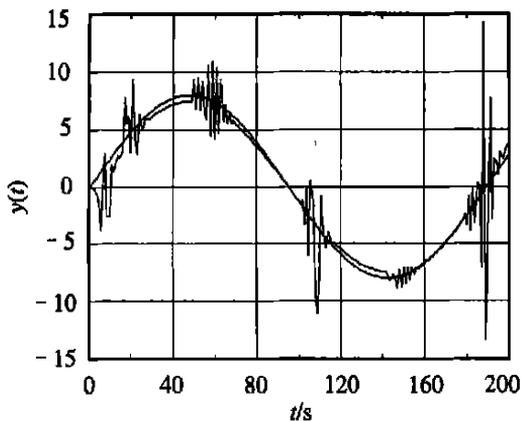


图2 方案1系统输出响应

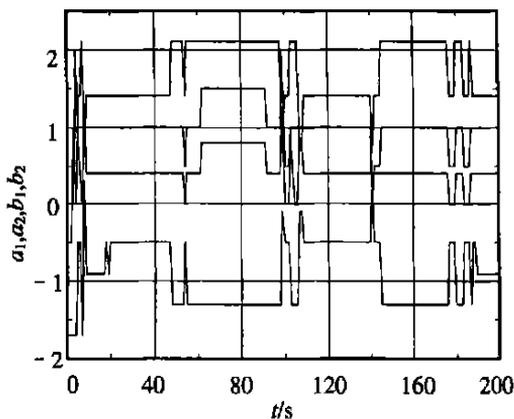


图3 方案1参数估计序列

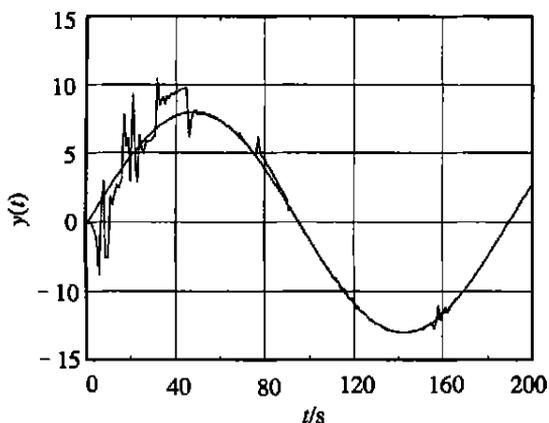


图4 方案2系统输出响应

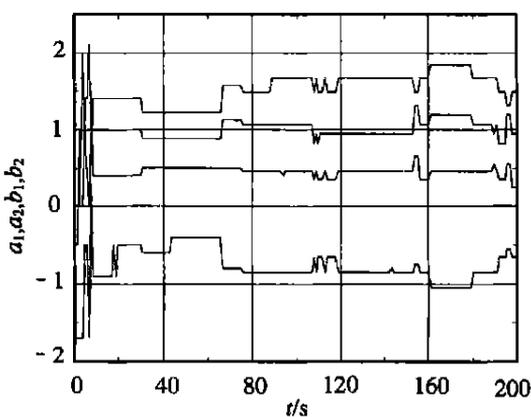


图5 方案2参数估计序列

优化算法, 滞后因子 $h = 0.02$ 。系统输出响应如图4所示, 对应的参数估计序列如图5所示。

比较图2和图4可见, 采用可变模型集方案要比采用固定模型集方案优越得多, 尤其是系统对多模型重新定位之后, 其跟踪特性有了显著的提高。比较图3和图5可见, 该现象的原因在于: 系统使用固定模型集对被控对象各参数进行估计, 在一个较大范围内会有波动, 但在采取在线优化措施之后, 系统的参数估计更加准确, 波动范围大大缩小, 从而使跟踪性能得到极大的提高。

5 结 语

分析上述在线优化方案, 设 $S_i/S_{i+1} = \mu^m$, $i = 0, 1, \dots$, 即每次优化都将估计区域减小到原来的 $1/\mu$, 并设子模型数量始终为 N 。经过 k 次类似优化后, 相当于减小了子模型的数量, 从而降低了计算复杂度。

本文提出的在线优化多模型算法能相对减少子模型数量, 大大提高控制精度和系统实时性, 具有较大的实用价值。该算法对于不确定时不变和慢时变系统取得了较好的控制效果, 而对于随机突变系统的在线优化方案还有待于进一步研究。

参考文献(References):

- [1] Athans M. The stochastic control of the F-8C aircraft using a multiple model adaptive control (MMAC) method — Part I: Equilibrium flight[J]. IEEE Trans on Autom Contr, 1977, 22(5): 768-780.
- [2] Narendra K S, Balakrish J, Ciliz M K. Adaptation and learning using multiple model, switching and tuning [J]. IEEE Contr Syst, 1995, 15(3): 37-51.
- [3] Middleton R H, Goodwin G C, Hill D J, et al. Design issues in adaptive control[J]. IEEE Trans on Autom Contr, 1988, 33(1): 50-58.