

核学习自适应预测控制器的在线更新方法

刘毅¹, 喻海清², 高增梁¹, 王海清², 李平²

(1. 浙江工业大学 特种装备制造与先进加工技术教育部重点实验室 化工机械设计研究所, 浙江 杭州 310032;

2. 浙江大学 工业控制研究所, 浙江 杭州 310027)

摘要: 针对非线性过程控制器的设计问题, 将基于稀疏核学习的一种具有解析形式的自适应预测控制算法与选择性递推核学习相结合. 该在线核学习模型可以通过递推算法进行节点增长和删减的有效更新. 因此, 所提出的控制器复杂度可控, 且能学习过程的时变等特性, 从而获得更好的性能. 通过一非线性时变过程的仿真研究, 验证了所提出的核学习控制器较传统的PID和无在线更新的核学习控制器等具有更好的自适应能力和鲁棒性.

关键词: 非线性过程控制; 递推辨识; 预测控制; 核学习

中图分类号: TP273; TP301.6 **文献标识码:** A

Online adaptation of kernel learning adaptive predictive controller

LIU Yi¹, YU Hai-qing², GAO Zeng-liang¹, WANG Hai-qing², LI Ping²

(1. Key Laboratory of Special Purpose Equipment and Advanced Processing Technology, Ministry of Education, Institute of Process Equipment and Control Engineering,

Zhejiang University of Technology, Hangzhou Zhejiang 310032, China;

2. Institute of Industrial Process Control, Zhejiang University, Hangzhou Zhejiang 310027, China)

Abstract: To design controllers for nonlinear processes, a sparse kernel learning adaptive predictive controller with an analytical form is extended to the updated form using the selective recursive kernel learning method. The online kernel learning model can be efficiently updated with node increment and decrement via recursive learning algorithms. Consequently, the proposed kernel controller can restrict its complexity and adaptively trace the time-varying characteristics of a process to achieve better performance. Simulation of the proposed kernel controller for a nonlinear time-varying process is performed. In comparing with the traditional PID controller and the related kernel controller without online updating, this controller exhibits more satisfactory adaptation and robustness.

Key words: nonlinear process control; recursive identification; predictive control; kernel learning

1 引言(Introduction)

当代流程工业过程对产品质量的要求日益增高, 对具有较强非线性动态和时变特性的复杂过程, 传统的PID控制器和线性控制方法难以获得满意的控制效果^[1]. 虽然基于神经网络和模糊系统的控制技术^[2~4]等在过去的20年里得到了广泛研究, 但在工业过程的应用还较少. 因此, 研究适合复杂非线性过程应用且简单的控制器具有重要意义^[1].

以支持向量机(support vector machine, SVM)为代表的稀疏核学习(sparse kernel learning, SKL)建模方法^[5]具有较好的推广性能, 较神经网络等方法更适合小样本非线性过程的建模. 多种核学习控制方法(如采用线性核和二次多项式核的SVM预测控制^[6]、基于多核或多模型切换的SVM预测控制^[7]、基于SVM的预测函数控制^[8], 具有解析形式

的核学习预测控制^[9]、采用优化算法的SVM预测控制^[10,11])化工过程的仿真和应用研究表明了较传统的PID和相对应的神经网络等控制方法更优.

然而, 目前大部分核学习控制器^[6~11]采用离线的SVM辨识模型, 当过程的时变性较严重时, 辨识模型如果不能及时在线更新, 准确程度会逐渐下降, 从而降低了控制器的性能. 虽然递推SVM辨识模型已用于控制器的在线更新^[12,13], 但由于递推SVM存在计算量大和收敛慢(某些情况下甚至无法收敛)等问题, 会导致所设计的控制器实时性能不好. Li等^[14]提出用在线的最小二乘SVM更新预测控制器, 较递推SVM可降低计算量, 但其辨识模型更新时采用的策略不能保证模型的推广性能, 控制品质也会降低.

为克服基于离线核学习模型控制器^[6~11]和已有的在线核学习控制器^[12~14]的缺点, 本文以文献^[9]具

有解析形式的控制方法为例,将其拓展为一种可简便递推更新且具有自适应能力的在线核学习控制器.主要创新点在于:采用选择性递推核学习建模方法^[15]更新离线核学习辨识模型,以更好的学习过程的时变等未知特性.该在线核学习模型的节点增长和删减均可快速递推更新,并采用基于预测误差准则的稀疏性策略来限制控制器的复杂度,从而保证控制器对过程的时变和未建模等特性具有较强的自适应性,最终有效的提高其综合性能.

2 核学习自适应预测控制器(Kernel learning adaptive predictive controller)

一大类非线性过程可表示为^[10,15]

$$\begin{cases} y(k+1) = f[\mathbf{Y}(k) \ u(k) \ \mathbf{U}(k-1)] = f[\mathbf{x}(k)], \\ \mathbf{x}(k) = [\mathbf{Y}(k) \ u(k) \ \mathbf{U}(k-1)], \\ \mathbf{Y}(k) = [y(k) \ \cdots \ y(k-n_y+1)], \\ \mathbf{U}(k-1) = [u(k-1) \ \cdots \ u(k-n_u+1)], \end{cases} \quad (1)$$

式中: $u(k)$ 和 $y(k)$ 分别是 k 时刻过程的调节变量和被控变量, n_u 和 n_y 为相应阶次, $f(\cdot)$ 为未知的非线性函数.采用并行形式的SKL辨识模型获得 $f(\cdot)$ 的预测输出 $y_m(k+1)$ ^[10]:

$$y_m(k+1) = \text{SKL}[\mathbf{x}(k), \mathbf{a}(k)] = \frac{1}{\gamma} \sum_{i=1}^{N_k} a_{N_k,i} \mathbf{K}(\mathbf{x}(i), \mathbf{x}(k)), \quad (2)$$

式中: N_k 为 k 时刻的节点(nodes,类似于SVM中的支持向量)数量; $\mathbf{K}(\mathbf{x}(i), \mathbf{x}(k))$ 为核函数; $\mathbf{a}(k)$ 为 k 时刻SKL模型的参数,由 $a_{N_k,i}$ 组成; γ 为正则化参数^[10].用过程的新息 $e(k) = y(k) - y_m(k)$ 来校正辨识模型的预测输出 $y_m(k+1)$ ^[6,9~11]:

$$y_p(k+1) = y_m(k+1) + e(k). \quad (3)$$

采用如下的一步加权预测控制性能指标设计控制器^[6,9~11]:

$$J[u(k)] = [E(k+1)]^2 + \lambda[u(k) - u(k-1)]^2, \quad (4)$$

式中: $E(k+1) = y_r(k+1) - y_p(k+1) = y_r(k+1) - y_m(k+1) - e(k)$, $y_r(k)$ 是 k 时刻的参考轨迹,由设定值获得, $\Delta u(k) = u(k) - u(k-1)$ 为控制量的变化, $\lambda(\lambda > 0)$ 表示控制作用的加权因子.在实际的过程控制中,通常希望获得简单的且具有解析形式的控制律,计算简便以适合在线执行.文献[9]提出一种具有解析形式的核学习预测控制器,主要通过Taylor线性化方法求取控制律如下:

$$u(k) = u(k-1) + \frac{\mu(k) \tilde{E}(k+1) \frac{\partial \text{SKL}}{\partial u(k)}|_{u(k-1)}}{\lambda + \left[\frac{\partial \text{SKL}}{\partial u(k)}|_{u(k-1)} \right]^2}, \quad (5)$$

式中: $\tilde{E}(k+1) = y_r(k+1) - \text{SKL}[\tilde{\mathbf{x}}(k)] - e(k)$ 为总预测误差, $\text{SKL}[\tilde{\mathbf{x}}(k)]$ 为SKL辨识模型的准预报输出, $\frac{\partial \text{SKL}}{\partial u(k)}|_{u(k-1)}$ 为 $u(k-1)$ 处的SKL灵敏度导数,时变参数 $\mu(k)$ 作为自适应修正项(adaptive modification item, AMI),以补偿Taylor线性化近似等给控制器造成的误差.文献[9]通过收敛性分析,最终获得 k 时刻收敛的具有自适应调整能力的控制律如下:

$$u(k) = u(k-1) + \frac{\tilde{E}(k+1)}{\frac{\partial \text{SKL}}{\partial u(k)}|_{\bar{u}(k-1)}}, \quad (6)$$

式中: $\bar{u}(k-1) \in [u(k-1), u(k)]$,通常取 $\bar{u}(k-1) = \frac{1}{2}[u(k-1) + u(k)]$ ^[9].该控制器主要采用了Taylor线性化方法,通过修正项 $\mu(k)$ 的自行调节以自适应调整控制律,故称为SKL-ATL(adaptive Taylor linearization)控制器.

3 SKL-ATL控制器的在线更新(Online updating of SKL-ATL controller)

3.1 控制器的复杂度策略(Complexity strategy of controller)

目前大部分SKL辨识算法均采用离线学习的方式,在线递推学习的研究还较少.离线模型主要缺点在于无法及时融合过程新的非线性和时变等信息,模型失配将导致基于离线辨识SKL模型(如离线训练的SVM模型)的控制器^[6~11]性能下降.因此,为保证基于SKL辨识模型的控制器的性能,需要在线更新辨识模型,使其能更及时准确的描述过程的动态和时变特性.

注意到SKL控制框架下的 N_k 可看作辨识模型的阶次代表其复杂度.为保证基于SKL辨识模型的控制器的性能得到及时更新,采用文献[15]提出的可递推的,且能自适应控制模型复杂度的选择性递推核学习(selective recursive kernel learning, SRKL)辨识方法对控制器进行有效更新.

设置一小的正数 δ 为预测误差限(prediction error bound, PEB),用于控制辨识模型的复杂度条件.则当预报误差满足下式时才更新辨识模型:

$$|e(k+1)| = |y(k+1) - y_m(k+1)| > \delta. \quad (7)$$

采用SRKL的选择性稀疏策略更新辨识模型可以获得稀疏的辨识模型以提高推广性能,并能够减少储存空间,其有效性在多个非线性Benchmark测试平台和化工反应过程辨识中得到了验证^[15].本文对该方法进行拓展,将模型辨识和控制器设计同时结合在一起,当被控对象精度要求很高时,PEB可取较小,反之亦然,如此可灵活的调整和设计.通常情况下,当被控过程运行在稳态时,预报误差总是很小,

此时无需更新模型;只有当过程发生变化时才可能需要更新模型,这有效降低模型的复杂度,进而简化了相应的控制器。相比之下,文献[14]提出的在线的最小二乘SVM更新预测控制器对所有样本点都进行考虑,导致在线模型变得复杂,因此需要更多的计算量和存储空间。

3.2 控制器的递推更新(Recursive updating of controller)

为获得 k 时刻SRKL的辨识模型,需求解如下方程组^[15]:

$$[\mathbf{K}_{N_k} + \mathbf{I}_{N_k}] \mathbf{a}_{N_k} = \mathbf{y}_{N_k}. \quad (8)$$

记 $\mathbf{H}_{N_k} = \mathbf{K}_{N_k} + \mathbf{I}_{N_k}$, $\mathbf{P}_{N_k} = \mathbf{H}_{N_k}^{-1}$,则此时SRKL模型的系数为

$$\mathbf{a}_{N_k} = \mathbf{P}_{N_k} \mathbf{y}_{N_k}. \quad (9)$$

当新节点加入原模型时,式(8)变为

$$\begin{bmatrix} \mathbf{H}_{N_k} & \mathbf{V}_{N_{k+1}} \\ \mathbf{V}_{N_{k+1}}^T & v_{N_{k+1}} \end{bmatrix} \begin{bmatrix} \mathbf{a}_{N_k} \\ a_{N_{k+1}} \end{bmatrix} = \begin{bmatrix} \mathbf{y}_{N_k} \\ y_{N_{k+1}} \end{bmatrix}, \quad (10)$$

式中: $v_{N_{k+1}} = \mathbf{K} \langle \mathbf{x}_{N_{k+1}}, \mathbf{x}_{N_{k+1}} \rangle + \frac{1}{\gamma}$ 为标量, $\mathbf{V}_{N_{k+1}} = [\mathbf{K} \langle \mathbf{x}_1, \mathbf{x}_{N_{k+1}} \rangle \cdots \mathbf{K} \langle \mathbf{x}_{N_k}, \mathbf{x}_{N_{k+1}} \rangle]^T / \gamma$ 是由新节点和原有节点构成的核向量。注意到求解 \mathbf{a}_{N_k} 的关键在于求矩阵 \mathbf{H}_{N_k} 的逆 \mathbf{P}_{N_k} 。根据矩阵和的求逆公式,可得 $\mathbf{P}_{N_{k+1}}$ 的递推式为^[15]

$$\mathbf{P}_{N_{k+1}} = \begin{bmatrix} \mathbf{P}_{N_k} & 0 \\ 0 & 0 \end{bmatrix} + \mathbf{r}_{N_{k+1}} \mathbf{r}_{N_{k+1}}^T z_{N_{k+1}}, \quad (11)$$

式中: $\mathbf{r}_{N_{k+1}} = [\mathbf{V}_{N_{k+1}}^T \mathbf{P}_{N_k} - 1]^T$, $z_{N_{k+1}} = \frac{1}{v_{N_{k+1}} - \mathbf{V}_{N_{k+1}}^T \mathbf{P}_{N_k} \mathbf{V}_{N_{k+1}}}$ 为标量。每增加一个节点,运算复杂度由原来的 $O(N_k^3)$ 减至 $O(N_k^2)$ 。因此,SRKL模型在节点增长时无需直接求逆, $\mathbf{P}_{N_{k+1}}$ 可由 \mathbf{P}_{N_k} 快速递推求得,降低了运算复杂度。

当过程时变特性较为严重时,有必要对模型进行修剪更新以保证模型的适应性;或者模型节点增长到一定程度后,需要对模型进行修剪以控制其复杂度,保证相应控制器的实时性能。传统的滑动时间窗方法是去掉最旧的样本,但这无法保证去掉的样本给原有模型造成的损失最小。文献[14]认为 $|\mathbf{a}(k)|$ 值较小的样本在模型中所起的作用较小,每次删减一小部分 $|\mathbf{a}(k)|$ 值较小的样本以缩减模型的冗余。但是,这两种方法都没有考虑删减样本后对原有模型的影响。文献[15]从在线更新模型的角度出发,提出了一种基于快速留一交叉验证的修剪算法,在保证计算性能的同时使得修剪后的模型能最低程度的降低原有模型的推广性能,并验证了比传统删减算法更能保证模型的建模性能。因此,本文采用此删减策

略对辨识模型和相应的控制器进行更新。

当某个节点被删除时,相应的矩阵 \mathbf{H}_{N_k} 要删掉一行一列,为避免直接求其逆矩阵,采用文献[15]的递推方法。每减少一个节点,运算复杂度也由原来的 $O(N_k^3)$ 减至 $O(N_k^2)$ 。

采用两阶段递推学习以及选择性节点增加和删减策略对SRKL模型进行有效更新,最终可获得具有自适应调整能力的,且可在线更新的SRKL-ATL控制律。当采用常用的Gaussian核时($\mathbf{K} \langle \mathbf{x}(i), \mathbf{x}(k) \rangle = \exp(-\|\mathbf{x}(i) - \mathbf{x}(k)\|^2 / \sigma^2)$,核参数 σ 为正数),SRKL辨识模型为

$$y_m(k+1) = \frac{1}{\gamma} \sum_{i=1}^{N_k} a_{N_k,i} \exp\left(-\frac{\|\mathbf{x}(i) - \mathbf{x}(k)\|^2}{\sigma^2}\right). \quad (12)$$

由式(12)可求得:

$$\tilde{E}(k+1) = y_r(k+1) - e(k) - \frac{1}{\gamma} \sum_{i=1}^{N_k} a_{N_k,i} \exp\left(-\frac{\|\mathbf{x}(i) - \mathbf{x}(k)\|^2}{\sigma^2}\right), \quad (13)$$

$$\begin{aligned} \frac{\partial \text{SRKL}}{\partial u(k)} \Big|_{\bar{u}(k-1)} = \\ \frac{2}{\gamma \sigma^2} \sum_{i=1}^{N_k} a_{N_k,i} \exp\left(-\frac{\|\mathbf{x}(i) - \mathbf{x}(k)\|^2}{\sigma^2}\right) \cdot \\ [\mathbf{x}_{N_y+1}(i) - \bar{u}(k-1)], \end{aligned} \quad (14)$$

式中:SRKL表示当前时刻的选择性递推核学习辨识模型, $\tilde{\mathbf{x}}(k) = [\mathbf{Y}(k) \ u(k-1) \ \mathbf{U}(k-1)]$, $\bar{\mathbf{x}}(k) = [\mathbf{Y}(k) \ \bar{u}(k-1) \ \mathbf{U}(k-1)]$, $\mathbf{x}_{N_y+1}(i)$ 为 $\mathbf{x}(i)$ 的第 N_y+1 项。由式(6)(13)(14)可得基于Gaussian核函数的SRKL-ATL控制律。

综上所述,SRKL-ATL控制器包括SRKL模型预测模块和自适应控制器两大模块。它与现有的核学习控制器^[6~11]的主要区别在于:本文的辨识模型是可以通过在线递推学习进行有效控制和更新的(包括节点的增长和修剪)。具体而言,SRKL辨识模型能有效的结合控制目标控制模型的复杂度,并自适应修正模型,在较准确描述非线性过程的同时具有较好的推广性能;而且,控制律具有简单的解析形式,计算量小,且能够自适应修正,对过程的变化响应更快速准确。这两方面共同保证了SRKL-ATL控制器比基于离线辨识模型的控制器^[6~11]具有更好的自适应控制能力。

4 仿真研究(Simulation study)

以一非线性时变过程^[3,4]说明SRKL-ATL控制器在各种情况下是如何自适应调节的,并与传统的PID^[4]以及没有在线更新的SVM-ATL控制方法^[4]相比较,以验证其有效性和优越性。文献[3]设计的神经网络自适应控制器需要过程准确的数学模型,这

在实际过程中通常较难满足;文献[4]采用递归模糊神经网络的广义预测控制方案,但控制器设计较为复杂且计算量大.该过程可描述为^[3,4]

$$\begin{aligned} y(k+1) = & 0.9722y(k) + 0.3578u(k) - \\ & 0.1295u(k-1) - 0.3103y(k)u(k) - \\ & 0.04228y^2(k-1) + 0.1663y(k-1)u(k-1) - \\ & 0.03259y^2(k)y(k-1) - 0.3513y^2(k)u(k-1) + \\ & 0.3084y(k)y(k-1)u(k-1) + \\ & 0.1087y(k-1)u(k)u(k-1). \end{aligned} \quad (15)$$

本文取 $\boldsymbol{x}(k) = [y(k) \ y(k-1) \ u(k) \ u(k-1)]^T$ ^[3,4], 选用Gaussian核函数,惩罚系数 $\gamma = 0.0001$ 和核函数宽度 $\sigma = 10$ 仿真选定^[15],PEB参数 $\delta = 0.02$ 结合控制目标设定,为表明参数选取的鲁棒性和控制算法的自适应调整能力,所有例子的 λ 均取为0.01.

4.1 与PID控制器比较(Comparison with PID controller)

首先通过跟踪文献[4]所示的方波来阐述SRKL-ATL的工作原理,并考察其控制效果.由图1可知系统的输出响应迅速且几乎没有超调,控制效果与文献[4]采用的基于递归模糊神经网络的广义预测控制差不多,优于文献[3]的神经网络自适应控制器.




图1 SRKL-ATL跟踪设定曲线

Fig. 1 Process output tracking of SRKL-ATL

SRKL-ATL控制器能自适应调节AMI以得到相应的 $u(k)$,过程的设定值一变,AMI即能作出相应的调整.如前所述,SRKL辨识模型通常在系统运行初

和工况切换时(即瞬态)更新,这是因为在这两阶段模型的辨识能力相对不足;当过程进入稳态后,由于没有新的工况变化,SRKL辨识模型保持不变,这也说明了模型增加样本时采用的选择性更新策略比文献[14]采用添加所有样本更实用.自适应进行复杂度控制能有效简化SRKL辨识模型,最终该例子50个样本点仅得到13个节点,稀疏率为26%.

为验证所提出的SRKL-ATL控制器的有效性,以下将SRKL-ATL与一经过优化整定的PID^[4]进行比较,以表明SRKL-ATL控制器的自适应性和鲁棒性.同时考虑有噪声和扰动情况,对系统的输出加入均值为0,方差为0.02的高斯白噪声,并在 $k = 25$ 和 $k = 75$ 处加入干扰.

两种控制方法的响应曲线如图2所示,从中可看出尽管此时输出含有噪声并受到较大的扰动,但SRKL-ATL控制器并没有受到太大的影响,尤其在扰动后很快就能恢复正常;而PID的抗干扰能力较差,受到扰动后恢复到稳态的过渡时间较长.以积分绝对误差(integrated absolute error, IAE)作为性能指标,得到SRKL-ATL和PID的IAE分别为8.21和10.10(如图2所示).为表明两种方法的抗干扰能力,进行100次Monte Carlo仿真实验,得到SRKL-ATL和PID的平均IAE分别为8.33和10.42.因此,SRKL-ATL的综合控制效果(跟踪和调节)均优于PID,对噪声和扰动具有更强的鲁棒性.

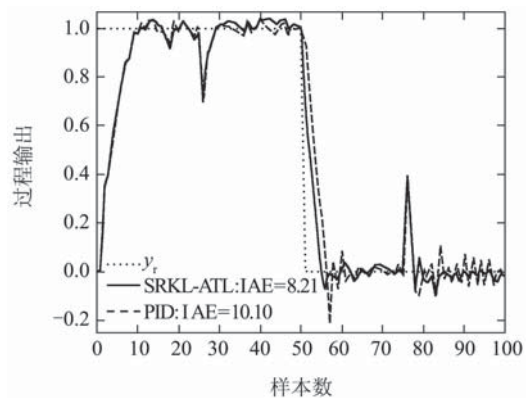


图2 有噪声和扰动时跟踪效果比较

Fig. 2 Comparison of noise and disturbance rejection

为进一步研究SRKL-ATL控制器的自适应性,考虑系统跟踪由两方波信号和一频率逐渐变大的正弦曲线组成的参考轨迹.图3给出了跟踪此波形时,SRKL-ATL和PID两类控制器的效果,可看出SRKL-ATL在不改变任何参数的情况下还能很好的跟踪新的参考轨迹.而PID无法跟踪前一部分的阶跃信号,这意味着PID参数必须重新整定;另一方面,在跟踪正弦波形时,随着频率的变大,PID慢慢跟不上节拍,并出现了较大的振荡.两方面均表明了SRKL-ATL较PID自适应性更好.




图 3 混合波形跟踪效果比较

Fig. 3 Performance comparison for hybrid waves

4.2 删减策略比较(Comparison of pruning strategies)

以跟踪图 3 的波形为例, 讨论预测误差限 δ 和 SRKL 模型复杂度以及控制器控制精度的关系, 并和文献[14]的删减策略比较以验证本文修剪算法的有效性. 当被控对象精度需要提高时, δ 必须减小, SRKL 模型的节点 N_k 会增加, 当超过最大节点 N 时需要启动修剪算法.

跟踪图 3 的波形, 首先设定 $N = 50$, 表 1 列出了 δ 的变化对 SRKL 模型复杂度以及相应 SRKL-ATL 控制性能的影响(包括 IAE 和计算时间), 其结果验证了如前分析. 当 $\delta = 0.002$ 和 $\delta = 0.001$ 时, SRKL 辨识模型需要修剪, 所得结果表明修剪算法能有效的去掉冗余节点以保证模型的复杂度.

表 1 不同 δ 对 SRKL 辨识模型及 SRKL-ATL 控制效果的影响

Table 1 The effect of different δ on performance of SRKL identification model and SRKL-ATL controller

	SRKL-ATL ($N = 50$)					PID
δ	0.02	0.01	0.005	0.002	0.001	
IAE	3.70	3.10	2.84	2.64	2.56	14.05
N_k	20	32	46	50	50	
Time/s	0.33	0.34	0.39	0.72	0.80	0.06

其次, 设定 $N = 20$, 表 2 给出了采用不同预测误差限 δ 时, 本文删减方法和文献[14]删减方法所得到的控制性能比较. 从中可知所提出的删减方法更能够保证控制器的性能, 这是因为修剪后的辨识模型能在留一交叉验证估计策略下最大程度的保证模型的推广性能^[15]. 相对来说, 文献[14]的删减方法并不能很好的去除模型的冗余, 当 $\delta = 0.002$ 变成 $\delta = 0.001$ 时, 删减后的模型控制性能反而稍微变差. 因此, 本文的删减方法优于文献[14]的删减方法.

表 2 不同删减方法对控制效果的影响

Table 2 The effect of different pruning methods on controller's performance

删减方法		SRKL-ATL ($N = 20$)				
	δ	0.02	0.01	0.005	0.002	0.001
本文	IAE	3.70	3.03	2.72	2.57	2.51
文献[14]	IAE	3.70	3.23	3.02	2.88	2.97

4.3 时变情况: 与无在线更新的 SVM-ATL 比较 (Comparison with SVM-ATL controller without online updating)

为考察 SRKL-ATL 控制器适应过程时变的情况, 假设过程出现两种时变情况. 第 1 种时变情况为式 (15) 前两个系数变成

$$y(k+1) = 0.8y(k) + 0.5u(k) + \dots, \quad (16)$$

$$25 \leq k \leq 75.$$

其余部分与式 (15) 相应部分一致. 控制效果如图 4 所示, 当系统时变时, SRKL 辨识模型立即在线更新(节点相应增加), AMI 也自适应进行调整, 保证了控制效果. 相比之下, 在系统时变后 PID 出现了振荡, 控制效果很差. 综合上述情况, 可知 SRKL-ATL 较优化整定的 PID 等对噪声、扰动和系统的时变均具有更好的鲁棒性和自适应性.

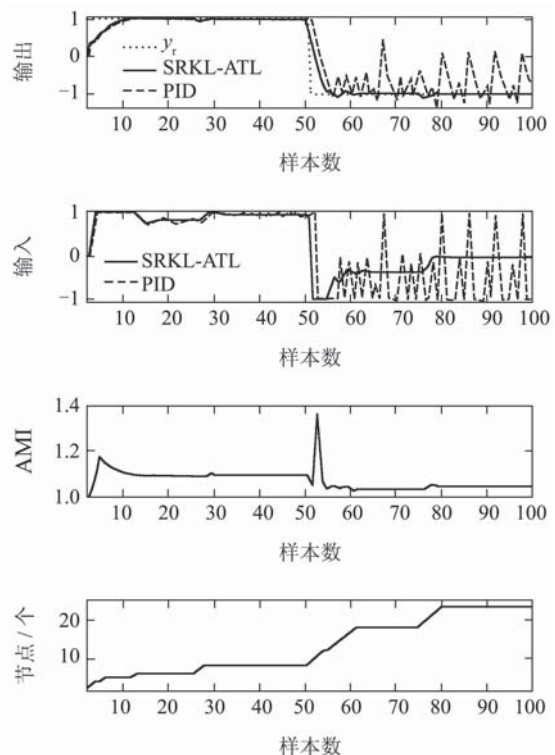


图 4 过程时变 1 时跟踪效果比较

Fig. 4 Performance comparison of SRKL-ATL and PID (process time-varying scenario 1)

第 2 种时变情况考虑过程参数的时变和模型失配, 情况更为复杂, 如下式所示:

$$y(k+1) =$$

$$0.9722y(k) + 0.3578p_{k1}u(k) - 0.1295u(k-1) - 0.3103p_{k1}y(k)u(k) - 0.04228y^2(k-1) + 0.1663y(k-1)u(k-1) - 0.03259y^2(k)y(k-1) + \text{model mismatch}, \quad (17)$$

其中: $p_{k1} = 1 + 0.03k$, $p_{k2} = 1 + 0.03k$.

图5给出了SRKL-ATL和没有在线更新的SVM-ATL^[9]两种控制器的控制效果. 一开始由于SRKL模型仍处于初始学习阶段, 跟踪性能SRKL-ATL较SVM-ATL差. 随着SRKL模型的及时更新, 过程的时变和非线性等信息能够不断融合进来(节点也相应增加), 因此最终控制效果更好. 与之相反的是, SVM-ATL是基于离线训练好的模型, 虽然一开始瞬态响应更好, 但模型没有及时更新, 随着过程时变特性的显著, 控制效果最终无法保证. 因此, 及时更新辨识模型是非常有必要的, 可以更好适应过程的变化, 以保证控制器的有效性.

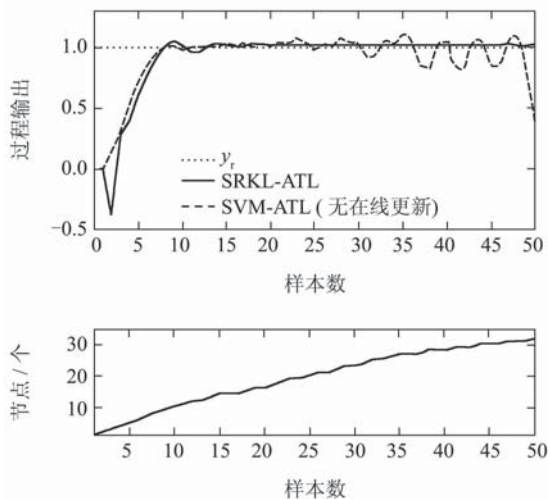


图5 过程时变2时跟踪效果比较(控制器有无更新)

Fig. 5 Performance comparison of SRKL-ATL and SVM-ATL(process time-varying scenario 2)

5 结论(Conclusion)

基于离线SKL辨识模型设计的预测控制和自适应控制算法已表现出比相应的神经网络控制器更好的性能. 本文主要将基于SKL辨识模型的控制器拓展为可在线递推更新的形式, 以更好的学习过程的时变等特性, 提高其综合性能. 所提出的SRKL-ATL控制器具有简单的解析形式, 复杂度可控, 节点增长和删减均可有效的在线递推更新. 仿真比较验证了SRKL-ATL对过程的时变等干扰具有较强的自适应调整能力, 控制性能整体优于整定的PID和没有在线更新的核学习控制器.

参考文献(References):

[1] MUKATI K, RASCH M, OGUNNAIKE B A. An alternative structure for next generation regulatory controllers. Part II: Stability analysis, tuning rules and experimental validation[J]. *Journal of Process Control*, 2009, 19(2): 272 – 287.

- [2] HIMMELBLAU D M. Accounts of experiences in the application of artificial neural networks in chemical engineering[J]. *Industrial & Engineering Chemistry Research*, 2008, 47(16): 5782 – 5796.
- [3] AHMED M S. Neural-net-based direct adaptive control for a class of nonlinear plants[J]. *IEEE Transactions on Automatic Control*, 2000, 45(1): 119 – 124.
- [4] LU C H, TSAI C C. Generalized predictive control using recurrent fuzzy neural networks for industrial processes[J]. *Journal of Process Control*, 2007, 17(1): 83 – 92.
- [5] BISHOP C M. *Pattern Recognition and Machine Learning*[M]. New York: Springer, 2006.
- [6] 钟伟民. 支持向量机在先进控制的应用研究[D]. 杭州: 浙江大学, 2006.
(ZHONG Weimin. *A study on the application of support vector machine in advanced control*[D]. Hangzhou: Zhejiang University, 2006.)
- [7] 包哲静. 支持向量机在智能建模和模型预测控制中的应用[D]. 杭州: 浙江大学, 2007.
(BAO Zhejing. *Applications of support vector machine in intelligent modeling and model predictive control*[D]. Hangzhou: Zhejiang University, 2007.)
- [8] ZHANG R D, WANG S Q. Support vector machine based predictive functional control design for output temperature of coking furnace[J]. *Journal of Process Control*, 2008, 18(5): 439 – 448.
- [9] LIU Y, WANG H Q, LI P. Kernel learning adaptive one-step-ahead predictive control for nonlinear processes[J]. *Asia-Pacific Journal of Chemical Engineering*, 2008, 3(6): 673 – 679.
- [10] 刘毅, 王海清, 李平. 采用Brent优化的核学习单步预测控制算法[J]. *控制理论与应用*, 2009, 26(1): 107 – 110.
(LIU Yi, WANG Haiqing, LI Ping. Kernel learning one-step-ahead predictive control algorithm using Brent optimization[J]. *Control Theory & Applications*, 2009, 26(1): 107 – 110.)
- [11] 穆朝絮, 张瑞民, 孙长银. 基于粒子群优化的非线性系统最小二乘支持向量机预测控制方法[J]. *控制理论与应用*, 2010, 27(2): 164 – 171.
(MU Chaoxu, ZHANG Ruimin, SUN Changyin. LS-SVM predictive control based on PSO for nonlinear systems[J]. *Control Theory & Applications*, 2010, 27(2): 164 – 171.)
- [12] IPLIKCI S. Online trained support vector machines-based generalized predictive control of non-linear systems[J]. *International Journal of Adaptive Control and Signal Processing*, 2006, 20(10): 599 – 621.
- [13] WANG H, PI D Y, SUN Y X. Online SVM regression algorithm-based adaptive inverse control[J]. *Neurocomputing*, 2007, 70(4/6): 952 – 959.
- [14] LI L J, SU H Y, CHU J. Generalized predictive control with online least squares support vector machines[J]. *Acta Automatica Sinica*, 2007, 33(11): 1182 – 1188.
- [15] LIU Y, WANG H Q, YU J, et al. Selective recursive kernel learning for online identification of nonlinear systems with NARX form[J]. *Journal of Process Control*, 2010, 20(2): 181 – 194.

作者简介:

刘毅 (1982—), 男, 博士, 研究领域为核学习自适应建模与控制及其工业应用等, E-mail: yliuzju@zjut.edu.cn, 本文通讯作者;

喻海清 (1974—), 男, 博士研究生, 研究领域为核学习建模方法等, E-mail: yu.hai.qing331@126.com;

高增梁 (1960—), 男, 博士, 教授, 研究领域为高效过程装备与控制等, E-mail: zlgao@zjut.edu.cn;

王海清 (1974—), 男, 博士, 副教授, 研究领域为工业过程的统计学习建模与过程监控等, E-mail: hqwang@iipc.zju.edu.cn;

李平 (1954—), 男, 博士, 教授, 研究领域为复杂工业过程建模与控制等, E-mail: pli@iipc.zju.edu.cn.