

基于在线支持向量回归的非线性模型预测控制方法

陈进东, 潘 丰

(江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘 要: 针对非线性模型预测控制中离线模型难以适应非线性对象实时变化的缺点, 提出一种基于在线支持向量回归的非线性模型预测控制方法. 该方法通过在线支持向量回归离线训练与在线学习相结合的方式, 建立具有在线校正特性的预测模型, 同时采用最速下降原理滚动优化非线性模型预测控制的目标函数, 求得多步控制量. 通过对非线性对象的控制结果表明, 所提出方法有效且具有良好的自适应性.

关键词: 非线性模型; 预测控制; 在线支持向量回归; 最速下降原理

中图分类号: TP273

文献标志码: A

Online support vector regression-based nonlinear model predictive control

CHEN Jin-dong, PAN Feng

(Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education, Jiangnan University, Wuxi 214122, China. Correspondent: PAN Feng, E-mail: pan_feng_63@163.com.cn)

Abstract: For off-line model hardly adapt to the real-time change of nonlinear object in nonlinear model predictive control (NMPC), an NMPC based on online support vector regression(OSVR) is developed. This algorithm utilizes OSVR off-line training and on-line learning to built nonlinear dynamical model with on-line adjusted capability. Furthermore, the multi-step control rules are obtained by the rolling optimization of gradient decent rule. Simulation results for a nonlinear system show the good adaptability and effectiveness of the proposed algorithm.

Key words: nonlinear model; predictive control; online support vector regression; gradient decent rule

0 引 言

模型预测控制(MPC)是一种利用预测模型控制被控对象输出的计算机控制算法, 预测模型的精确度在MPC中起到非常重要的作用^[1]. 经典的预测控制算法, 一般通过被控对象的单位阶跃响应或脉冲响应估计所需模型参数, 得到其近似线性模型^[2]. 但是对于强非线性被控对象, 这些方法便会出现模型失配的问题, 从而导致预测控制器性能下降^[3].

针对传统MPC算法难以建立非线性被控对象的准确预测模型的缺点, 学者们提出了基于支持向量机(SVM)的MPC^[4-7]. SVM是一种基于VC维理论和结构风险最小化的统计学习方法, 较好地解决了局部最优、非线性、小样本训练等问题^[8]. 然而, 以往的方法一般采用离线训练模型, 不能在线学习校正模型, 而非线性过程一般均具有时变性, 离线建立的模型难以

适应这种变化^[9]. 在线支持向量回归(OSVR)是一种SVM在线训练方法^[10], 当模型偏差超过设定误差时, 通过保存训练过程中间变量能够进行在线学习, 校正模型参数. 虽然OSVR的计算效率不是很高^[11], 但是由于其在线学习能力可以有效地消除模型失配的影响, 使得系统能够在较短的时间得到稳定.

滚动优化是MPC最主要的特征, 即通过求解目标函数确定未来的控制量, 并且在线反复进行^[2]. 但预测模型越来越复杂, 使得目标函数的直接最优求解变得十分困难, 因此很多学者提出采用非线性优化方法对目标函数进行寻优, 主要方法有牛顿法^[12]、共轭梯度法^[13]、粒子群优化^[14]、遗传算法^[15]等, 然而目前还没有一种快速、有效的求解目标函数的非线性优化方法. 最速下降法是一种广泛使用的非线性优化方法, 具有寻优速度快、精度高、存储变量较少等优点^[16], 非常适合MPC目标函数求解快速准确的要求.

收稿日期: 2012-11-12; 修回日期: 2013-03-05.

基金项目: 国家自然科学基金项目(61273131); 江苏高校优势学科建设工程项目.

作者简介: 陈进东(1983—), 男, 博士生, 从事过程优化建模与控制的研究; 潘丰(1963—), 男, 教授, 博士生导师, 从事过程优化建模与控制等研究.

鉴于此, 本文提出一种基于OSVR的非线性MPC算法(OSVR-NMPC). 通过OSVR离线建立被控对象的预测模型, 并利用其在线学习能力, 在线校正预测模型, 保证了预测模型的精确度. 在每个采样点上, 利用最速下降法滚动优化非线性目标函数, 求得所需的控制量, 从而实现非线性自适应MPC.

1 方法和步骤

OSVR 具有较好的泛化能力, 能够在线对预测模型参数进行校正, 因此适用于非线性对象建模, 算法详细步骤见文献[10].

OSVR-NMPC方法结构如图1所示. 图1中, y_{sp} 为参考轨迹 y_r 的设定值, y 为实际的输出值, y_m 为模型的预测输出, y_p 为反馈校正后的预测输出, u 为控制器输出, err 为系统实际输出与模型预测输出之间的偏差.

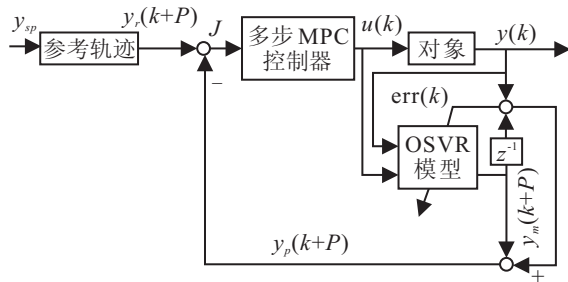


图1 OSVR-NMPC方法框图

1.1 非线性预测模型

假定非线性系统如下所示:

$$\begin{aligned} y(k+1) = & \\ & f[y(k), y(k-1), \dots, y(k-n_y+1), \\ & u(k), u(k-1), \dots, u(k-m_u+1)]. \end{aligned} \quad (1)$$

其中: f 为非线性方程, 系统的阶次 n_y 和 m_u 均未知. OSVR算法是基于核函数的非线性回归, 有

$$\begin{aligned} y_m(k+1) = & \\ & \hat{f}[y(k), y(k-1), \dots, y(k-n'+1), \\ & u(k), u(k-1), \dots, u(k-m'+1)]. \end{aligned} \quad (2)$$

其中: \hat{f} 为通过OSVR训练得到的非线性方程, n' 和 m' 的阶次由拟合的精确度来确定. 令

$$\begin{aligned} \mathbf{X}(k) = & \\ & [y(k), y(k-1), \dots, y(k-n'+1), \\ & u(k), u(k-1), \dots, u(k-m'+1)], \end{aligned} \quad (3)$$

可得

$$\hat{f}(\mathbf{X}) = \sum_{i=1}^l \theta_i K[\mathbf{X}(i), \mathbf{X}] + b, \quad (4)$$

其中 $K[\mathbf{X}(i), \mathbf{X}]$ 为核函数, 一般为径向基函数(RBF).

通过训练数据 $\mathbf{X}(i+1), y(i) (i = 1, 2, \dots, l)$ 可以

获得 $\theta_i (i = 1, 2, \dots, l)$ 和偏离值 b , 因此在 k 时刻预测模型的下一步输出为

$$y_m(k+1) = \hat{f}[\mathbf{X}(k)] = \sum_{i=1}^l \theta_i K[\mathbf{X}(i), \mathbf{X}(k)] + b, \quad (5)$$

其中

$$\begin{aligned} \mathbf{X}(k) = & \\ & [y(k), y(k-1), \dots, y(k-n'+1), \\ & u(k), u(k-1), \dots, u(k-m'+1)]. \end{aligned}$$

为了获得多步预测输出, 移动式(5)中的时域, 并假设 $n' \geq P, m' \geq P$. P 为预测时域, $y_m(k+j)$ 为在 k 时刻的第 j 步预测输出, 有

$$\begin{aligned} y_m(k+2) = \hat{f}[\mathbf{X}'(k+1)] = & \\ & \sum_{i=1}^l \theta_i K[\mathbf{X}(i), \mathbf{X}'(k+1)] + b. \end{aligned}$$

其中

$$\begin{aligned} \mathbf{X}'(k+1) = & \\ & [y_m(k+1), y(k), \dots, y(k-n'+2), \\ & u(k+1), u(k), \dots, u(k-m'+2)]; \\ & \vdots \\ y_m(k+P) = & \\ & \hat{f}[\mathbf{X}'(k+P-1)] = \\ & \sum_{i=1}^l \theta_i K[\mathbf{X}(i), \mathbf{X}'(k+P-1)] + b, \\ \mathbf{X}'(k+P-1) = & \\ & [y_m(k+P-1), \dots, y_m(k+1), \\ & y(k), \dots, y(k-n'+P), \\ & u(k+P-1), \dots, u(k), \dots, u(k-m'+P)]. \end{aligned} \quad (6)$$

为了处理模型的失真和系统的干扰, 实施在线校正模型参数策略, 通过将反馈误差 $err(k) = |y(k) - y_m(k)|$ 与设定误差 $\min\text{-err}$ 比较决定是否进行在线学习. 为了提高算法的在线学习速度, 只对超过设定误差的样本进行训练. 因此, 如果反馈误差 $err(k) < \min\text{-err}$, 则表明模型精度较高, 不需要校正; 若 $err(k) \geq \min\text{-err}$, 则表明模型失配, 需要将此样本带入训练集进行在线学习.

1.2 非线性预测控制器

OSVR-NMPC的目标函数为

$$J(k) = \frac{1}{2} \sum_{j=1}^P [y_r(k+j) - y_p(k+j)]^2. \quad (7)$$

其中: $y_p(k+j)$ 为第 j 步预测输出, 有

$$y_p(k+j) = y_m(k+j) + err(k); \quad (8)$$

$y_r(k+j)$ 为第 j 步参考输出, 有

$$\begin{cases} y_r(k) = y(k), \\ y_r(k+j) = \alpha_r y_r(k+j-1) + (1-\alpha_r) y_{sp}(k). \end{cases} \quad (9)$$

α_r 为控制系统的鲁棒性和收敛性相关的调整因子, $0 < \alpha_r < 1$, $y_{sp}(k)$ 为真实的设定值.

将式 (7) 写成向量形式

$$\begin{aligned} \mathbf{J} &= \frac{1}{2} [\mathbf{Y}_r(k) - \mathbf{Y}_p(k)]^T [\mathbf{Y}_r(k) - \mathbf{Y}_p(k)] = \\ &= \frac{1}{2} \mathbf{E}^T(k) \mathbf{E}(k). \end{aligned} \quad (10)$$

其中

$$\mathbf{Y}_r(k) = [y_r(k+1), y_r(k+2), \dots, y_r(k+P)]^T;$$

$$\mathbf{Y}_p(k) = [y_p(k+1), y_p(k+2), \dots, y_p(k+P)]^T;$$

$$\mathbf{E}(k) = [e(k+1), e(k+2), \dots, e(k+P)]^T;$$

$$e(k+j) = y_r(k+j) - y_p(k+j), \quad j = 1, 2, \dots, P.$$

定义 k 时刻的控制输入信号

$$\mathbf{U}_k = [u(k), u(k+1), \dots, u(k+P-1)]^T. \quad (11)$$

预测控制滚动优化的目标是求得使目标方程 J 最小的控制输入 \mathbf{U}_k . 由最速下降原理可以得到

$$\mathbf{U}_k^{t+1} = \mathbf{U}_k^t - \eta_c \frac{\partial \mathbf{J}}{\partial \mathbf{U}_k^t}. \quad (12)$$

其中: t 为循环的次数; η_c 为学习速率; 且有

$$\frac{\partial \mathbf{J}}{\partial \mathbf{U}_k^t} = -\frac{\partial \mathbf{Y}_p(k)^T}{\partial \mathbf{U}_k^t} \mathbf{E}(k), \quad (13)$$

$$\begin{aligned} \frac{\partial \mathbf{Y}_p(k)^T}{\partial \mathbf{U}_k^t} = & \begin{bmatrix} \frac{\partial y_m(k+1)}{\partial u(k)} & \frac{\partial y_m(k+2)}{\partial u(k)} & \dots & \frac{\partial y_m(k+P)}{\partial u(k)} \\ 0 & \frac{\partial y_m(k+2)}{\partial u(k+1)} & \dots & \frac{\partial y_m(k+P)}{\partial u(k+1)} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & \frac{\partial y_m(k+P)}{\partial u(k+P-1)} \end{bmatrix}. \end{aligned} \quad (14)$$

因此, 式 (14) 中的每个元素都可以通过 (15) 对 (11) 的变量求偏微分得到, 即

$$\begin{aligned} \frac{\partial y_m(k+n)}{\partial u(k+m-1)} = & \frac{\partial \hat{f}[\mathbf{X}(k+n)]}{\partial u(k+m-1)} + \\ & \sum_{i=m}^{n-1} \frac{\partial \hat{f}[\mathbf{X}(k+i)]}{\partial y_m(k+i)} \left[\frac{\partial y_m(k+i)}{\partial u(k+m-1)} \right]. \end{aligned} \quad (15)$$

其中: $n = 1, 2, \dots, P$, $m = 1, 2, \dots, P$. 由文献 [16] 可知, 式 (15) 可以简化为

$$\frac{\partial y_m(k+n)}{\partial u(k+m-1)} =$$

$$\frac{\partial y_m(k+n-1)}{\partial u(k+m-1)} \left\{ 1 + \frac{\partial \hat{f}[\mathbf{X}(k+n-1)]}{\partial y_m(k+n-1)} \right\}. \quad (16)$$

由于 OSVR 一般采用 RBF 核函数, 有

$$\begin{aligned} \frac{\partial y_m(k+n-1)}{\partial u(k+m-1)} = & \frac{2}{\sigma^2} \sum_{i=1}^l \theta_i \exp(-\|\mathbf{X}(i) - \mathbf{X}'(k+n-1)\|^2/\sigma^2) \times \\ & [x_{n'+1}(i) - u(k+m-1)], \end{aligned} \quad (17)$$

$$\begin{aligned} \frac{\partial \hat{f}[\mathbf{X}(k+n-1)]}{\partial y_m(k+n-1)} = & \frac{2}{\sigma^2} \sum_{i=1}^l \theta_i \exp(-\|\mathbf{X}(i) - \mathbf{X}'(k+n-1)\|^2/\sigma^2) \times \\ & [x_1(i) - y_m(k+n-1)]. \end{aligned} \quad (18)$$

其中: $x_{n'+1}(i)$ 为输入向量 $\mathbf{X}(i)$ 的第 $n'+1$ 个向量, $x_1(i)$ 为 $\mathbf{X}(i)$ 的第 1 个向量.

通过式 (17) 和 (18), 可以求得 (16) 的值, 在此基础上求出式 (14) 中每个元素的值; 再求解式 (13) 和 (12), 得到 $t+1$ 次循环后的多步控制量. 采用最速下降原理多次寻优, 直到目标函数满足终止精度时停止优化, 从而得到 k 时刻的多步控制律. 模型预测控制将在线反复进行该优化过程, 实现滚动优化.

1.3 算法的步骤

OSVR-NMPC 的整体步骤如下.

Step 1: 选择合适的参数, 包括 $C, \varepsilon, \sigma, \text{min-err}, n', m', \alpha_r, P$ 和 η_c .

Step 2: 为了提高模型的运算速率, 对模型进行离线训练, 得到 $\theta_i (i = 1, 2, \dots, l)$ 和 b .

Step 3: 在采样时间 k , 通过比较模型输出和系统实际输出得到其预测误差 $\text{err}(k)$.

Step 4: 如果 $\text{err}(k) < \text{min-err}$, 则将此输入输出向量加入训练集, OSVR 模型保持不变; 如果 $\text{err}(k) \geq \text{min-err}$, 则先将此输入输出向量加入训练集, 然后在已有的模型参数基础上, 通过在线训练方法逐步调整预测模型参数.

Step 5: 通过式 (9) 计算参考估计 $y_r(k+j)$, $j = 1, 2, \dots, P$.

Step 6: 通过最速下降法求解目标函数的最优控制量, 设定式 (11) 的初始值和目标函数的设定精度.

Step 7: 通过式 (6) 中的 $y_m(k+j)$ 和 (16) 中的 $u(k+j)$ 更新输入向量 $\mathbf{X}(k+j)$, $j = 1, 2, \dots, P$.

Step 8: 通过式 (17) 和 (18) 求出 (16) 的值.

Step 9: 通过式 (16) 求出 (14) 中每个元素的值, 再由式 (12) 和 (13) 求出未来控制输入向量.

Step 10: 循环优化, 直到满足终止误差, 结束寻优, 得到最优控制量 \mathbf{U}_k .

Step 11: 将第1个控制器输出 $u(k)$ 应用到对象, 得到系统的输出 $y(k+1)$.

Step 12: 增加 k , 即令 $k+1 \rightarrow k$, 返回 Step 3, 重复整个过程.

2 仿真研究

采用基准问题式 (19) 验证 OSVR-NMPC 的有效性

$$y(k) = \frac{0.7y(k-1)y(k-2)}{1+y(k-1)^2+y(k-2)^2} + 0.5 \cos(0.4y(k-1)) + 1.5u(k-1). \quad (19)$$

针对式 (19) 所示的非线性系统, 采用 OSVR-NMPC 算法进行控制. 为了提高算法的运算效率, 首先采用 OSVR 进行离线建模, 建模所需数据通过输入均值为 0、方差为 1 的白噪声信号产生, 共产生 400 个样本. 输入向量 X 的阶次选定 $n' = 4$ 和 $m' = 4$, 输出为 $y(k+1)$. 采用 10 折交叉验证方法进行 OSVR 离线训练^[7], 从而设定参数 $C = 500, \varepsilon = 0.1, \sigma = 0.7$.

为了更接近实际环境, 对于式 (19) 所示的非线性系统加入均值为 0、方差为 0.01 的高斯噪声影响. 采用 OSVR 离线模型对加入噪声的系统进行预测, 从而设定在线学习的阈值 $\min\text{-err}$, 预测结果如图 2 所示.




图 2 基于 OSVR 的模型预测结果

由图 2 可见, OSVR 离线模型的预测精度较高, 大部分预测误差均保持在 0.05 以内, 只有 3 次超过 0.05. 为了保证 OSVR-NMPC 算法的计算效率, 在保证预测模型精度的情况下, 设定 $\min\text{-err} = 0.05$. 对加入高斯噪声的系统进行预测控制时, 给定信号为方波信号, 控制参数 $P = 3$, 柔化系数 $\alpha_r = 0.2, \eta_c = 0.02$, 目标方程的终止误差为 0.01. 当 $k = 90$ 时, 将非线性对象式 (19) 的常数项 0.7, 0.5 分别增大 50%, 变为 1.05, 0.75, 从而导致预测模型失配. 将 OSVR-NMPC 的控制结果与基于 SVM 的非线性 MPC(SVM-NMPC)^[4] 进行比较, 控制结果如图 3 和图 4 所示.

由图 3 可见, 在模型匹配的情况下, OSVR-NMPC 与 SVM-NMPC 控制效果基本相似, 超调量很小, 且系统响应曲线比较平稳, 都能较快地将系统稳定到设

定值上. 由于在 $k = 90$ 时, 系统参数发生了变化, 从而导致模型失配. OSVR-NMPC 通过 OSVR 的在线学习, 能够使得系统较快地稳定在设定值上, 而 SVM-NMPC 需要更长的时间才能将系统稳定. 对于此后的阶跃信号, 由于 OSVR-NMPC 已经消除了模型失配的影响, 控制输出比较稳定, 超调量很小; 由于 SVM-NMPC 不具备在线学习能力, 只能通过反馈校正使系统输出稳定在设定值上, 但需要较长时间.




图 3 OSVR-NMPC 和 SVM-NMPC 控制结果




图 4 OSVR-NMPC 和 SVM-NMPC 控制输入

3 结论

本文针对强非线性对象提出了一种基于 OSVR 的非线性模型预测控制算法. 通过 OSVR 建立非线性对象的预测模型, 并利用 OSVR 的在线学习能力, 实现了模型在线自校正. 利用最速下降法对目标函数求解, 实现了自适应控制. 通过对非线性对象的仿真研究, 验证了该方法不仅在模型精确的情况下控制结果较好, 而且即使在模型失配的情况下也能够通过在线学习校正预测模型, 从而消除模型失配带来的影响, 取得较好的控制效果, 具有很好的自适应能力和实用性.

参考文献(References)

[1] 舒迪前. 预测控制系统及其应用[M]. 北京: 机械工业出版社, 1996: 1-36.
(Shu D Q. Predictive control system and its application[M]. Beijing: China Machine Press, 1996: 1-36.)
[2] 席裕庚. 预测控制[M]. 北京: 国防工业出版社, 1993: 5-18.
(Xi Y G. Predictive control[M]. Beijing: National Defense Industry Press, 1993: 5-18.)

- [3] Qin S J, Badgwell T A. A survey of industrial model predictive control technology[J]. *Control Engineering Practice*, 2003, 11(7): 733-764.
- [4] Zhong W, Pi D. Support vector machine based nonlinear model multi-step-ahead optimizing predictive control[J]. *J of Central South University of Technology*, 2005, 12(5): 591-595.
- [5] 郭振凯, 宋召青, 毛剑琴. 基于最小二乘支持向量机的非线性广义预测控制[J]. *控制与决策*, 2009, 24(4): 520-525.
(Guo Z K, Song Z Q, Mao J Q. Nonlinear generalized predictive control based on least square support vector machine[J]. *Control and Decision*, 2009, 24(4): 520-525.)
- [6] Shin J, Jin K H, Kim Y. Adaptive support vector regression for UAV flight control[J]. *Neural Networks*, 2011, 24(1): 109-120.
- [7] Liu Y, Gao Y, Gao Z, et al. Simple nonlinear predictive control strategy for chemical processes using sparse kernel learning with polynomial form[J]. *Industrial & Engineering Chemistry Research*, 2010, 49(17): 8209-8218.
- [8] Vapnik V N. *The nature of statistical learning theory*[M]. New York: Springer, 1999: 23-103.
- [9] Liu Y, Chen W, Wang H, et al. Adaptive control of nonlinear time-varying processes using selective recursive kernel learning method[J]. *Industrial & Engineering Chemistry Research*, 2011, 50(5): 2773-2780.
- [10] Ma J, James T, Simon P. Accurate on-line support vector regression[J]. *Neural Computation*, 2003, 15(11): 2683-2704.
- [11] Liu Y, Wang H, Yu J, et al. Selective recursive kernel learning for online identification of nonlinear systems with NARX form[J]. *J of Process Control*, 2010, 20(2): 181-194.
- [12] 王寅, 荣冈, 王树青. 基于TS模糊模型的非线性预测控制策略[J]. *控制理论与应用*, 2002, 19(4): 599-603.
(Wang Y, Rong G, Wang S Q. Nonlinear predictive control strategy based on T-S fuzzy model[J]. *Control Theory & Applications*, 2002, 19(4): 599-603.)
- [13] Dostál Z. *Optimal quadratic programming algorithms: With applications to variational inequalities*[M]. New York: Springer, 2009: 27-35.
- [14] 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): 164-168.
(Mu Z X, Zhang R M, Sun C Y. LS-SVM predictive control based on PSO for nonlinear systems[J]. *Control Theory & Applications*, 2010, 27(2): 164-168.)
- [15] Yuzgec U, Becerikli Y, Turker M. Dynamic neural-network-based model-predictive control of an industrial baker's yeast drying process[J]. *IEEE Trans on Neural Networks*, 2008, 19(7): 1231-1242.
- [16] Noriega J R, Wang H. A direct adaptive neural-network control for unknown nonlinear systems and its application[J]. *IEEE Trans on Neural Networks*, 1998, 9(1): 27-34.

(责任编辑: 郑晓蕾)