

文章编号: 1000-8152(2009)10-1180-05

基于即时学习的非线性系统自适应PID控制

潘天红¹, 李少远²

(1. 江苏大学 电气信息工程学院, 江苏 镇江 212013; 2. 上海交通大学 自动化系, 上海 200240)

摘要: 当使用先进策略整定PID控制器参数时, 往往要依赖于系统所辨识的模型, 而模型的精度与优化算法的计算效率直接影响到系统的控制效果. 本文利用即时学习算法的本质自适应特点(建模数据在时间与空间上相邻性), 来提高辨识模型的精度, 并基于广义最小方差的性能指标, 用等价多项式的方法, 推导出PID形式的控制律, 从而避免其他优化算法带来的计算量, 提高了控制精度与计算效率. 仿真结果验证了该方法的有效性.

关键词: 广义最小方差; 即时学习; k 矢量近邻; PID 控制器

中图分类号: TP273 **文献标识码:** A

Adaptive PID control for nonlinear systems based on lazy learning

PAN Tian-hong¹, LI Shao-yuan²

(1. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang Jiangsu 212013, China;

2. Institute of Automation, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: When applying advanced strategies to determine the parameters of a PID controller, a model need to be identified for the controlled system. The predicted precision and the computation efficiency of the identifying algorithm directly affect the control performance of the system. To improve the precision, lazy learning algorithm, which has a essentially adaptive characteristics(i.e., in which the data used for modeling are not only neighbors in time domain, but also neighbors in space domain), is used to identify the model of system. By employing the generalized minimum variance as the performance function and using the polynomial method, the control-law is derived for the PID controller, in which its parameters are tuned online in the process of the lazy learning identification. Simulation results show good performances of this algorithm.

Key words: general minimum variance; lazy learning; k -vector nearest neighbors; PID controller

1 引言(Introduction)

非线性系统往往具有较强的不确定性, 时变性, 使用常规的PID控制器难以达到理想的控制效果; 并且PID控制器参数的整定, 往往需要丰富的经验与反复的尝试, 工作量大, 而且未必能达到目的, 这就限制了PID控制器的广泛使用.

随着控制理论与技术的发展, 许多学者提出了多种自适应在线调整策略, 如: 基于滚动优化策略的参数自校正^[1]、基于广义最小方差的参数调整^[2]等. 在使用这些先进策略时, 往往需要辨识系统当前工况下的模型, 而模型的获取通常有在线与离线两种方法. 前者往往采用滚动数据窗口(receding horizon window, RHW)辨识系统当前工作点的局部线性模型^[1]; 而后者则需事先建立整个系统的非线性模型(如神经网络模型)^[2,3], 然后在工作点处线性化得到系统的局部线性模型. 这些策略在实际应用中都取得了不错的效果. 但对于大范围, 强非线性,

或者跳跃性变化的系统, 采用滚动数据窗口的方法, 由于滚动策略, 丢弃了过去的历史数据, 仅仅依靠当前时间窗口中的数据, 辨识的模型不准确, 难以获得良好的控制效果. 而离线建立的全局模型, 由于新的工况出现, 往往需要重新训练, 再次离线建模, 工作量大.

为克服上述问题, 本文利用即时学习(lazy learning, LL)算法^[4]本质的自适应(建模数据在时间与空间相邻的特性), 提出用 k -VNN(k -vector nearest neighbors)搜索策略^[5], 从系统累积的数据中找出与当前模态相匹配的数据集合, 采用局部多项式拟合算法^[4]建立系统的局部线性模型. 并基于广义最小方差的性能指标, 用等价多项式方法, 推导出具有PID结构形式的控制律, 减少优化算法整定PID参数带来的计算量, 从而实现了对非线性系统自

适应PID控制.

2 局部线性模型在线辨识(Online identification of locally linear model)

假定被控系统可用如下NARX模型表示:

$$y(t) = f(\phi(t-1)) + \varepsilon(t). \quad (1)$$

式中:

$$\begin{aligned} \phi(t-1) = & [y(t-1), \dots, y(t-n_y), u(t-p), \dots, \\ & u(t-p-n_u)]^T \end{aligned}$$

为 t 时刻系统的状态向量, 维数为 $m(m = n_y + n_u)$; $n_y, n_u, p > 0$ 为系统的输出、输入阶次与时延; $y(t), u(t), \varepsilon(t)$ 为系统的输出、输入和零均值的白噪声; $f(\cdot)$ 为未知的非线性函数.

关于系统(1)的物理描述未知, 但存在 N 组输入输出数据 $\{y(i), \phi(i)\}_{i=1}^N$, 在当前 t 时刻, 由系统的输入信息 $\phi(t)$, 采用 k -VNN搜索策略^[5], 在系统已有的数据中寻找 k 组最相似的数据($k \ll N$), 具体如下:

1) 当 $\cos \beta(\phi(i), \phi(t)) < 0$, 则认为此 $\phi(i)$ 偏离于当前工作点, 不利于系统建模, 丢弃此数据;

2) 否则, 以 $\phi(i)$ 与 $\phi(t)$ 的指数核与夹角余弦加权之和构成选择准则, 即

$$\begin{aligned} D(\phi(i), \phi(t)) = & \alpha \cdot e^{-d(\phi(i), \phi(t))} + (1-\alpha) \cdot \cos \beta(\phi(i), \phi(t)). \quad (2) \end{aligned}$$

式中:

$$\begin{aligned} \cos \beta(\phi(i), \phi(t)) = & \frac{\phi^T(i)\phi(t)}{\|\phi(i)\|_2 \cdot \|\phi(t)\|_2}, \\ d(\phi(i), \phi(t)) = & \|\phi(i) - \phi(t)\|_2, \alpha \in [0, 1] \end{aligned}$$

为加权因子.

由式(2)可知, 加权选择准则 $D(\phi(i), \phi(t))$ 直接反映了 $\phi(i)$ 与 $\phi(t)$ 的相似性. 若两个信息向量越靠近, 则 d 就越小, e^{-d} 越大, 并且 $\cos \beta$ 也就越大, 从而 $D(\phi(i), \phi(t))$ 也就越大.

这样, 在已有的数据信息中, 以式(2)为准则, 选择 $D(\cdot)$ 值最大的 k 组数据, 按降序排列, 构造学习集:

$$\begin{aligned} & \{(\phi(1), y(1)), \dots, (\phi(k), y(k))\}, \\ & D(\phi(1), \phi(t)) > \dots > D(\phi(k), \phi(t)). \quad (3) \end{aligned}$$

线性回归这些信息向量, 即可得到系统当前工况下的局部线性模型. 但由于在不同工况点, 符合当前工况点 $\phi(t)$ 的数据密度可能不一样, 用于建模的数据个数也是不定的, 亦即: 建模邻域 k 值大小可变, 为了获得最佳的线性模型 $\hat{\theta}$, 同时减小计算量, 可预先设定领域的变化范围 $k \in [k_m, k_M](k_m < k_M)$, 在计

算近邻 $k+1$ 的局部模型 θ_{k+1} 时, 直接利用近邻 k 的模型值 θ_k , 采用递归最小二乘算法, 得到系统模型

$$\begin{cases} \psi_{k+1} = \Phi_{k+1}^T P_k \Phi_{k+1} + 1/D_{k+1}, \\ \gamma_{k+1} = P_k \Phi_{k+1} \psi_{k+1}^{-1}, \\ e_{k+1} = y(k+1) - \Phi_{k+1}^T \hat{\theta}_k, \\ \hat{\theta}_{k+1} = \hat{\theta}_k + \gamma_{k+1} e_{k+1}, \\ P_{k+1} = P_k - \gamma_{k+1} \gamma_{k+1}^T \psi_{k+1}. \end{cases} \quad (4)$$

得到近邻 $k+1$ 的模型 θ_{k+1} , 同时, 也可以得到近邻 $k+1$ 的去一交叉误差值^[4]

$$\begin{aligned} e_{k+1,j}^{\text{loo}} = y(j) - \Phi_j \hat{\theta}_{k+1}^{-j} = & \frac{y(j) - \Phi_j^T \hat{\theta}_{k+1}}{1 - \Phi_j^T P_{k+1} \Phi_j}, \\ j = & 1, 2, \dots, k+1. \end{aligned} \quad (5)$$

式中: $\hat{\theta}_{k+1}^{-j}$ 表示在 $k+1$ 组数据中, 用去掉第 j 个数据所得到的局部模型; $e_{k+1,j}^{\text{loo}}$ 表示实际值 $y(j)$ 与模型 $\hat{\theta}_{k+1}^{-j}$ 得到的预测值之间的误差.

这样, 可以得到近邻 $k+1$ 的去一交叉误差集 $\{e_{k+1,j}^{\text{loo}}\}_{j=1}^{k+1}$, $k+1 \leq k_M$, 均方和这些 $e_{k+1,j}^{\text{loo}}$, 得

$$E^{\text{loo}}(k+1) = \frac{\sum_{j=1}^{k+1} w_j (e_{k+1,j}^{\text{loo}})^2}{\sum_{j=1}^{k+1} w_j}. \quad (6)$$

式中: 加权因子 $w_j = \sqrt{D(\phi(j), \phi(t))}$ 直接反映每个 $\phi(j)$ 的去一交叉误差对 $E^{\text{loo}}(k+1)$ “贡献”大小. 越靠近 $\phi(t)$ 的 $\phi(j)$, 其“贡献”越大, 反之越小. 此时, 若

$$E^{\text{loo}}(k+1) > E^{\text{loo}}(k), k+1 \in [k_m, k_M]. \quad (7)$$

则认为模型“变差”, 停止回归计算, 并以模型 θ_k 作为系统当前时刻的最佳模型. 否则, 按照式(4), 从学习集式(3)中选取新的信息向量, 继续迭代, 直到 $k = k_M$ 为止. 这样, 可以及时判断局部模型的优劣, 得到当前时刻系统最佳的局部线性模型.

3 基于广义最小方差的PID控制器设计(PID controller design based on GMV)

在当前工况下, 由上述即时学习算法得到系统的模型参数 $\hat{\theta}_k$, 亦可转化得到 $\phi(t)$ 的线性模型:

$$A(z^{-1})y(t) = z^{-p}B(z^{-1})u(t) + d. \quad (8)$$

式中:

$$\begin{aligned} A(z^{-1}) = & 1 + a_1 z^{-1} + \dots + a_{n_y} z^{-n_y}, \\ B(z^{-1}) = & b_0 + \dots + b_{n_u} z^{-n_u}, \end{aligned}$$

d 同式(4).

3.1 典型的PID控制器(Typical PID controller)

典型的增量式PID控制器表达式为^[1~3]

$$\Delta u(t) = (w_0 + w_1 z^{-1} + w_2 z^{-2})e(t). \quad (9)$$

式中:

$$w_0 = K_p(1 + \frac{T_s}{T_i} + \frac{T_d}{T_s}),$$

$$w_1 = -K_p(1 + \frac{2T_d}{T_s}), w_2 = K_p \frac{T_d}{T_s},$$

K_p, T_i, T_d 分别为PID控制器的比例、积分时间和微分时间常数; T_s 为采样周期. 定义

$$W(z^{-1}) = w_0 + w_1 z^{-1} + w_2 z^{-2},$$

$$e(t) = r(t) - y(t).$$

则式(9)可转化为

$$W(z^{-1})y(t) - W(z^{-1})r(t) + \Delta u(t) = 0. \quad (10)$$

3.2 基于广义最小方差的PID控制器设计(PID controller design based on GMV)

式(11)两边同乘以算子 $\Delta(\Delta = 1 - z^{-1})$, 得

$$\Delta A(z^{-1})y(t) = z^{-p}B(z^{-1})\Delta u(t). \quad (11)$$

引入Diophantine方程:

$$P(z^{-1}) = \Delta A(z^{-1})F(z^{-1}) + z^{-p}G(z^{-1}), \quad (12)$$

式中:

$$F(z^{-1}) = 1 + f_1 z^{-1} + \dots + f_{n_f} z^{-n_f},$$

$$G(z^{-1}) = g_0 + g_1 z^{-1} + g_2 z^{-2},$$

$$\deg(F(z^{-1})) = p - 1.$$

从而

$$y(t+p) = [G(z^{-1})y(t) + F(z^{-1})B(z^{-1})\Delta u(t)]/P(z^{-1}), \quad (13)$$

即为系统在 $(t+p)$ 时刻的最优预报输出值 $y(t+p)$.

在广义最小方差控制算法中, 为了限制实际过程中的控制信号变化剧烈, 在性能指标中引入了对控制增量的加权项, 即目标函数为^[6]

$$J = \frac{1}{2}[P(z^{-1})y(t+p) - R(z^{-1})r(t)]^2 + \frac{1}{2}[Q\Delta u(t)]^2. \quad (14)$$

定义辅助系统模型:

$$S(t+p) = P(z^{-1})y(t+p) - R(z^{-1})r(t) + Q\Delta u(t). \quad (15)$$

这样, 求解广义最小方差的控制律, 等价于对辅助系统求解, 使其最小所得到的控制律^[7], 即

$$J = \frac{1}{2}[P(z^{-1})y(t+p) - R(z^{-1})r(t) + Q\Delta u(t)]^2. \quad (16)$$

极小化性能指标, 可得

$$G(z^{-1})y(t) - R(z^{-1})r(t) + [F(z^{-1})B(z^{-1}) + Q]\Delta u(t) = 0. \quad (17)$$

为获得PID结构形式的控制律, 控制增量的系数可以用稳态增益表示^[7], 即

$$F(z^{-1})B(z^{-1}) + Q = F(1)B(1) + Q,$$

故有

$$\frac{G(z^{-1})}{F(1)B(1) + Q}y(t) - \frac{R(z^{-1})}{F(1)B(1) + Q}r(t) + \Delta u(t) = 0. \quad (18)$$

与式(10)相比, 可得

$$\begin{cases} R(z^{-1}) = G(z^{-1}), \\ W(z^{-1}) = \frac{G(z^{-1})}{F(1)B(1) + Q}, \end{cases} \quad (19)$$

从而得到PID控制器的参数:

$$\begin{cases} K_p = -\frac{g_1 + g_2}{F(1)B(1) + Q}, \\ T_i = -\frac{(g_1 + 2g_2)T_s}{g_0 + g_1 + g_2}, \\ T_d = -\frac{g_2 T_s}{g_1 + 2g_2}. \end{cases} \quad (20)$$

3.3 算法实现(Algorithm realization)

整个非线性系统的PID控制器在线调节由两个阶段构成, 第1阶段在系统的当前工作点, 由即时学习算法获取系统的最佳局部线性模型; 在此基础上, 用广义最小方差性能指标优化PID控制器的参数, 整个系统的结构框图如图1所示.




图1 基于即时学习的PID控制器参数设计结构框图
Fig. 1 The scheme of optimal PID controller parameter design based on lazy learning

图1设计过程可概括为

Step 1 在当前 t 时刻, 得到系统的输入向量 $\phi(t)$;

Step 2 采用 k -VNN搜索策略, 由式(4)得到当前时刻的系统局部线性模型式(8);

Step 3 由式(12), 算出 $G(z^{-1})$ 多项式的系数;

Step 4 由式(20)算出PID控制器的参数;

Step 5 由式(9)算出 $\Delta u(t)$, 作用于系统;

Step 6 即时更新系统的历史数据集.

4 仿真验证(Simulation)

CSTR是化工过程的重要单元, 具有很强的非线性特性, 是化工系统中一类典型的非线性对象, 其输入输出动力学方程为^[8]

$$\begin{cases} \frac{dC_a}{dt} = \frac{q}{V}(C_{af} - C_a) - k_0 C_a \exp(-E/RT), \\ \frac{dT}{dt} = \frac{q}{V}(T_f - T) + \frac{(-\Delta H)k_0 C_a}{\rho C_p} \exp(-E/RT) + \frac{\rho_c C_{pc}}{\rho C_p} Q_c [1 - \exp(\frac{-hA}{Q_c \rho_c C_{pc}})](T_{cf} - T). \end{cases} \quad (21)$$

这里: C_a 是反应器内生成物A的浓度值, T 是反应物温度, q 是进出料流量(一般假设反应器的进出料相等), Q_c 是冷却剂流量, T_{cf} 是冷却剂进口温度, T_c 是冷却剂出口温度, C_{af} 是进料浓度, T_f 进料温度. 通过调节冷却剂流量 Q_c 的大小, 可控制反应器内温度 T , 进而控制反应物的浓度 C_a . 根据工艺要求, 确定 C_a 和 T 为过程输出, Q_c 为控制变量, T_c , q 和 C_{af} 为外部扰动变量. 各物理参数如表1所示^[8]. 表中 Q_{c0} , T_0 和 C_{a0} 分别为CSTR的一个稳态工作点对应的稳态值. 在稳态工作点, 用冷却剂流量 $Q_{c0} = 103.41 \text{ L/min}$ 变化 $\pm 20\%$ 时, 产生2000组样本.

构造模型的输入信息向量:

$$\phi(t-1) = [T(t-1), T(t-2), Q_c(t-1), Q_c(t-2)],$$

则局部模型阶次: $n_y = 2$, $n_u = 1$, 即时学习在线建模的参数为: $\alpha = 0.85$, $k \in [12, 100]$, PID控制器的惩罚项 $Q = 9.3$, 在跟踪 $T(446.5 \rightarrow 434.5 \rightarrow 438.5)$ 输出变量设定值变化效果如图2所示.

图2表明在系统工作点发生移动时, 即时学习算法(LL)所选择的建模数据由于时间与空间相邻的特性, 能够快速跟踪系统的变化, 从而获得PID控制器的参数具有更强的自适应性. 其控制效果也优于基于滚动数据时间窗体辨识(RHW)获取控制器参数的方法. 在整个跟踪轨迹中, 基于即时学习辨识的PID控制, 其控制器的参数变化轨迹如图3所示.

表 1 模型(21)中所用参数

Table 1 Parameters used in Eq.(21)

参数	取值
q	100 L/min
T_f	350 K
V	100 L
k_0	$7.2 \times 10^{10} \text{ L/min}$
$-\Delta H$	$2 \times 10^5 \text{ cal/mol}$
C_p, C_{pc}	1 cal/(g · K)
T_0	440.2 K
T_s	0.1 min
C_{af}	1.0 mol/L
T_{cf}	350 K
hA	$7 \times 10^5 \text{ cal/(min} \cdot \text{k}^{-1})$
E/R	$9.95 \times 10^3 \text{ K}$
ρ, ρ_c	1000 g/L
Q_{c0}	103.41 L/min
C_{a0}	0.0836 mol/L




图 2 控制效果对比图

Fig. 2 The results of different methods




图 3 PID控制器参数的变化轨迹

Fig. 3 The trajectories of PID controller's parameters

5 结论(Conclusion)

即时学习算法建模算法的本质自适应特点,易于与自适应控制相结合,本文在广义最小方差的性能指标下,获得PID结构形式的控制器,其控制器参数由于即时学习在线辨识获得,现将该算法总结如下:

1) 采用即时学习算法对非线性系统的局部辨识,由于其本质的自适应,学习精度高,适于大范围工况动态系统的实时控制;

2) 即时学习的在线更新历史数据库策略,提高系统的自适应性,有利于系统适应新的工况,克服系统出现新的工况,二次离线建模的弊端;

3) PID控制器的目标函数为广义最小方差,求得的控制器鲁棒性好,结构简单,计算量小,能克服PID参数在线整定的困难。

参考文献(References):

- [1] XU M, LI S Y, CAI W J. Receding horizon optimization approach to PID controller parameters auto tuning[J]. *Acta Automatica Sinica*, 2005, 31(3): 459 – 463.
- [2] CHEN J H, HUANG T C. Applying neural networks to online updated PID controller for nonlinear process control[J]. *Journal of Process Control*, 2004, 14(2): 211 – 230.
- [3] ZHANG Y, CHEN Z Q, YUAN Z Z. Nonlinear system PID-type multi-step predictive control[J]. *Journal of Control Theory & Applications*, 2004, 21(2): 201 – 204.
- [4] BONTEMPI G, BIRATTARI M. From linearization to lazy learning: a survey of divide-and-conquer techniques for nonlinear control[J]. *International Journal of Computational Cognition*, 2005, 3(1): 56 – 73.
- [5] 潘天红, 李少远, 王昕. 基于即时学习的非线性系统多模型建模方法[C] //第24届中国控制会议论文集. 广州: 华南理工大学出版社, 2005: 268 – 273.
(PAN Tianhong, LI Shaoyuan, WANG Xin. A multi-model modeling approach to nonlinear systems based on lazy Learning[C] //Proceeding of the 24th Chinese Control Conference. Guangzhou: South China University of Technology, 2005: 268 – 273.)
- [6] 富月, 柴天佑. 一类非线性非最小相位系统的直接自适应控制[J]. *控制理论与应用*, 2006, 23(6): 886 – 890.
(FU Yue, CHAI Tianyou. Direct adaptive control for a class of nonlinear non-minimum phase systems[J]. *Control Theory & Applications*, 2006, 23(6): 886 – 890.)
- [7] YAMAMOTO T, SHAH S L. Design and experimental evaluation of a multivariable self-tuning PID controller[J]. *IEEE Proceedings: Control Theory and Applications*, 2004, 151(5): 645 – 652.
- [8] LIGHTBODY G, IRWIN G W. Nonlinear control structures based on embedded neural system models[J]. *IEEE Transactions on Neural Networks*, 1997, 8(3): 553 – 567.

作者简介:

潘天红 (1974—), 男, 博士, 副教授, 主要研究方向为非线性系统多模型建模方法与应用、机器学习算法等, E-mail: thpan@ujs.edu.cn;

李少远 (1965—), 男, 教授, 博士生导师, 研究领域为预测控制、优化理论、Fuzzy系统等, E-mail: syli@sjtu.edu.cn.