

文章编号: 1001-0920(2007)05-0549-05

# 基于支持向量机 N4SID 辨识模型的非线性预测控制

向立志, 史运涛, 高东杰

(中国科学院 自动化研究所 综合自动化工程研究中心, 北京 100080)

**摘 要:** 针对工业控制领域中非线性系统的模型辨识与预测控制问题, 采用最小二乘支持向量机回归方法构造非线性函数, 运用状态子空间(N4SID)模型辨识方法辨识非线性状态空间模型, 在此基础上建立非线性预测控制器, 利用拟牛顿算法进行非线性预测控制律的求解, 从而实现了一种新的基于支持向量机 N4SID 辨识模型的非线性预测控制算法. 仿真实验验证了该算法的有效性和可行性.

**关键词:** 最小二乘支持向量机; N4SID 模型辨识; 非线性状态空间模型; 非线性预测控制; 拟牛顿算法

**中图分类号:** TP273

**文献标识码:** A

## Nonlinear model predictive control based on N4SID model identification using support vector machines

XIANGLi-zhi, SHI Yun-tao, GAO Dong-jie

(1. Engineering Research Center of Integrated Automation Technology, Institute of Automation, Chinese Academy of Science, Beijing 100080, China. Correspondent: XIANG Li-zhi, E-mail: lizhi.xiang@ia.ac.cn)

**Abstract:** To the problems of the model identification and predictive control of nonlinear systems in the domain of industry control, a nonlinear model predictive control algorithm is presented. The nonlinear function is constructed by least squares support vector machines regression. A numerical algorithm for subspace state space system identification is utilized to identify a nonlinear state-space model, which is used to construct a nonlinear model predictive controller. In deriving the control law, a quasi-Newton algorithm is applied to implement the nonlinear model predictive control (NMPC) algorithm. The simulation result shows the validity and feasibility of the NMPC algorithm.

**Key words:** Least square support vector machines; N4SID identification; Nonlinear state space model; Nonlinear predictive control; Quasi-Newton algorithm

### 1 引言

工业被控对象或多或少都存在一定的非线性, 因此非线性系统的控制问题已成为当前工业控制领域的研究热点. 但由于对象的非线性特性千差万别、极其复杂, 非线性系统的控制不可能象线性系统的控制那样容易实现. 对于非线性特性已经明确的简单系统, 通过建立机理模型便可实现相应的控制, 而对于事先不明确具体非线性形式的复杂系统, 要想通过机理建模去实现控制是很困难的.

如何实现非线性形式不明确的被控对象的控制? 一种有效的思路是: 首先根据实验获得原始的输入输出数据, 运用机器学习的方法学习对象的非线性特性, 即非线性系统辨识; 然后根据辨识得到的非线性模型建立控制器、构造控制回路, 从而实现非

线性控制.

Vapnik 等人<sup>[1,2]</sup>提出的支持向量机函数估计(统计学上称为回归)算法, 依据统计学习理论<sup>[3]</sup>中的结构风险最小化原则, 能够很好地估计出非线性对象的非线性特性, 这为工业控制中未知非线性系统的建模与控制提供了一种解决问题的具体方法. 该方法首先利用支持向量机函数去估计被控对象的非线性特性, 从而辨识出基于支持向量机的非线性模型; 然后利用这一模型构造非线性控制算法, 进而实施控制. 王宇红等人将基于 LS-SVM 的非线性辨识模型应用于预测控制, 提出了基于 LS-SVM 的非线性预测控制技术<sup>[4]</sup>. Suykens 等人<sup>[5]</sup>提出了基于最小二乘支持向量机的最优控制算法. 这些研究对支持向量机在非线性控制的应用作了有益的尝试.

收稿日期: 2006-01-10; 修回日期: 2006-03-31.

基金项目: 中科院知识创新工程重大项目(KGCX-SW-15).

作者简介: 向立志(1977—), 男, 四川通江人, 博士生, 从事先进控制理论与应用的研究; 高东杰(1943—), 男, 沈阳人, 研究员, 博士生导师, 从事先进控制技术等研究.

本文从非线性预测控制理论的角度,在 Geothals 等人<sup>[8]</sup>提出的最小二乘支持向量机 N4SID 模型辨识方法的基础上,辨识非线性状态空间模型,建立非线性预测控制器,从而实现了一种新的基于支持向量机的非线性预测控制算法。

## 2 最小二乘支持向量机函数估计算法

Suykens 等人<sup>[6,7]</sup>将支持向量机原始形式的不等式约束改为等式约束,提出了最小二乘形式的支持向量机算法,并将最小二乘支持向量机用于非线性函数的估计。

给定  $n$  维采样数据  $\{(u_k, y_k) | k = 1, 2, \dots, N\}$ , 其中  $u_k$  为输入数据,  $y_k$  为输出数据. 考虑函数模型为  $y_k = f(u_k) + e_k$ , 其中  $f$  是未知的非线性实函数,  $\{e_k | k = 1, 2, \dots, N\}$  是均值为零、方差为  $\sigma^2$  且互不相关的随机误差。

下面用最小二乘支持向量机算法来估计非线性实函数  $f$ . 假设非线性函数为

$$f(u) = w^T \Phi(u) + c. \quad (1)$$

其中:  $\Phi(u): R^n \rightarrow R^{n_f}$  为核空间映射函数,  $c$  为偏差量. 定义如下函数估计问题:

$$\begin{aligned} \min_{w, c, e} J(w, e) &= \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2, \\ \text{s.t. } y_k &= w^T \Phi(u_k) + c + e_k, k = 1, 2, \dots, N. \end{aligned} \quad (2)$$

其中  $\gamma$  为可调的正常数. 为了求解这个等式约束的最优化问题, 构造拉格朗日函数

$$L(w, c, e; \alpha) = J(w, e) - \sum_{k=1}^N \alpha_k (w^T \Phi(u_k) + c + e_k - y_k), \quad (3)$$

其中  $\alpha_k$  为拉格朗日乘子. 求解最优化条件可得矩阵方程

$$\begin{bmatrix} 0 & 1_N^T \\ 1_N & \Omega + \gamma^{-1} I_N \end{bmatrix} \begin{bmatrix} c \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}. \quad (4)$$

由矩阵方程(4)可以解得参数  $(\alpha, c)$ . 其中:  $y = [y_1, \dots, y_N]^T$ ,  $1_N = [1, \dots, 1]^T$ ,  $\alpha = [\alpha_1, \dots, \alpha_N]^T$ ,  $\Omega_{ii} = \Phi(u_i)^T \Phi(u_i) = K(u_i, u_i)$ . 本文核函数  $K(\cdot, \cdot)$  选为高斯径向基函数(RBF), 即

$$K(u_k, u_i) = \exp(-\|u_k - u_i\|_2^2 / (2\sigma^2)). \quad (5)$$

所得最小二乘支持向量机函数估计模型如下:

$$\begin{aligned} f(u) &= \sum_{sv} \alpha_{sv} K(u, u_{sv}) + c = \\ &= \sum_{sv} \alpha_{sv} \exp\left(-\frac{\|u - u_{sv}\|_2^2}{2\sigma^2}\right) + c. \end{aligned} \quad (6)$$

其中:  $(\alpha, c)$  是矩阵方程(4)的解, 下标  $sv$  表示支持向量。

## 3 最小二乘支持向量机 N4SID 模型辨识

从非线性模型辨识的角度出发, Geothals 等人<sup>[8]</sup>依据 Hammerstein 非线性模型结构, 提出了基于最小二乘支持向量机的非线性模型辨识方法。

Hammerstein 非线性模型是在线性动态系统的基础上, 加上一个输入端的静态非线性估计环节, 从而在整体上构成一个非线性模型. 假设线性动态部分是状态空间模型结构, 那么 Hammerstein 非线性模型的结构形式如图1所示。



图1 Hammerstein 非线性状态空间模型结构

上述 Hammerstein 非线性状态空间模型的数学表达式为

$$\begin{cases} x_{t+1} = Ax_t + Bf(u_t) + w_t, \\ y_t = Cx_t + Df(u_t) + v_t. \end{cases} \quad (7)$$

其中静态非线性部分  $f$  采用式(1)的最小二乘支持向量机函数估计形式。

Hammerstein 非线性状态空间模型的 N4SID 子空间辨识方法如下<sup>[8]</sup>:

- 1) 构造输入 / 输出 Hankel 矩阵;
- 2) 计算斜投影  $O_i$  和  $O_{i+1}$ ;
- 3) 对斜投影  $O_i$  进行奇异值分解;
- 4) 计算广义可观矩阵  $\Gamma_i$  和  $\Gamma_{i-1}$ ;
- 5) 计算状态序列的估计值  $\bar{X}_i$  和  $\bar{X}_{i+1}$ ;
- 6) 由状态序列的估计值, 构造最小二乘支持向量机最优化问题, 计算状态矩阵  $A$  和  $C$  的估计值, 并通过奇异值分解计算出状态矩阵  $B$  和  $D$  及非线性函数  $f$  的估计值。

由上述辨识步骤可计算出  $A, B, C, D$  和  $f$  的估计值, 并用最小二乘函数估计方法将  $f$  表示成式(6)的形式. 这样便得到整个 Hammerstein 非线性状态空间模型的通用表达式, 即

$$\begin{aligned} x_{t+1} &= Ax_t + B \left( \sum_{sv} \alpha_{sv} K(u_t, u_{sv}) + c \right) + w_t, \\ y_t &= Cx_t + D \left( \sum_{sv} \alpha_{sv} K(u_t, u_{sv}) + c \right) + v_t. \end{aligned} \quad (8a)$$

$$\quad (8b)$$

本文选择核函数  $K(\cdot, \cdot)$  为高斯径向基函数, 于是 Hammerstein 非线性状态空间模型的具体表达式为

$$\begin{aligned} x_{t+1} &= Ax_t + B \left( \sum_{sv} \alpha_{sv} \exp\left(-\frac{\|u_t - u_{sv}\|_2^2}{2\sigma^2}\right) + c \right) + w_t, \\ y_t &= Cx_t + D \left( \sum_{sv} \alpha_{sv} \exp\left(-\frac{\|u_t - u_{sv}\|_2^2}{2\sigma^2}\right) + c \right) + v_t, \end{aligned} \quad (9a)$$

$$y_t = Cx_t + D\left(\sum_{sv}^N \alpha_{sv} \exp\left(-\frac{\|u_t - u_{sv}\|^2}{2\sigma^2}\right) + c\right) + v_t.$$

(9b)

4 基于支持向量机的非线性预测控制算法

文献[9]将多层感知器(MLP)神经网络非线性模型作为预测模型,实现了一种基于神经网络模型的非线性预测控制.本文依据同样的思想,将上述最小二乘支持向量机非线性 N4SID 辨识模型引入预测控制领域,形成了下述基于最小二乘支持向量机 N4SID 辨识模型的非线性预测控制算法.




图 2 非线性预测控制算法原理

非线性预测控制的原理如图 2 所示.其基本思想是在每个控制周期内最小化性能指标函数

$$J = \sum_{i=N_1+1}^{N_2} [r(t+i) - \hat{y}(t+i)]^2 + \rho \sum_{i=1}^{N_u} [\Delta u(t+i-1)]^2,$$

(10)

以求取  $N_u$  个控制输入

$$U(t) = [u(t), \cdots, u(t+N_u-1)]^T,$$

使得非线性系统在  $N_u$  个控制周期以后理论上满足如下必要条件:

$$\{\Delta u(t+i) = 0, N_u \leq i \leq N_2\}.$$

其中: $N_1$  和  $N_2$  分别是最小和最大预测时域, $N_u$  是控制时域, $\rho$ 是控制增量权重系数.

4.1 预测模型

在  $t$  时刻,系统的一步向前预测输出是由当前的状态和输入构成的非线性函数,即

$$\hat{y}(t+1|t) = CAx_t + CBf(u_t) + Df(u_{t+1}).$$

(11)

依次类推,在  $t$  时刻系统的  $k$  步向前预测输出值可表示为

$$\hat{y}(t+k|t) = CA^k x_t + \sum_{i=1}^k CA^{i-1} Bf(u_{t+k-i}) + Df(u_{t+k}).$$

(12)

选择核函数为高斯径向基函数,则非线性预测模型的具体形式为

$$\hat{y}(t+k|t) = CA^k x_t + \sum_{i=1}^k CA^{i-1} Bf(u_{t+k-i}) + Df(u_{t+k}) = CA^k x_t + \sum_{i=1}^k CA^{i-1} B \times$$

$$\left(\sum_{sv}^N \alpha_{sv} \exp\left(-\frac{\|u_{t+k-i} - u_{sv}\|^2}{2\sigma^2}\right) + c\right) + D\left(\sum_{sv}^N \alpha_{sv} \exp\left(-\frac{\|u_{t+k} - u_{sv}\|^2}{2\sigma^2}\right) + c\right).$$

(13)

4.2 性能指标函数

将线性系统的预测控制算法<sup>[10]</sup>应用于非线性系统,其性能指标函数的矩阵形式如下:

$$J(U(t)) = E^T(t) E(t) + \Delta U^T(t) \Delta U(t) = [R(t) - Y(t)]^T [R(t) - Y(t)] + \Delta U^T(t) \Delta U(t).$$

(14)

可以看出,性能指标函数的基本形式不变,只是其中的  $Y(t)$  变成了式(13)的非线性形式.

4.3 计算预测控制律

计算预测控制律的过程就是在预测模型为式(13)的情况下,在每一控制周期内循环求解性能指标函数(14)最小值的非线性优化过程.即在每一控制周期内求解

$$\min_{U(t)} J(U(t)),$$

s. t.  $\hat{y}(t+k) = CA^k x_t + \sum_{i=1}^k CA^{i-1} Bf(u_{t+k-i}) + Df(u_{t+k}).$

(15)

从而得到预测控制输入序列  $U(t)$ ,取其第 1 项作为系统的控制量输入,然后进入下一控制周期,继续同样的优化求解.

由于这一非线性优化问题没有解析解,为了求解而采用拟牛顿算法.其基本思想是运用迭代搜索策略反复寻找预测控制输入序列  $U^{(i+1)} = U^{(i)} + \mu^{(i)} f^{(i)}$ ,最终使得  $U^{(i)}$  满足关键条件  $|U^{(i)} - U^{(i-1)}| < \delta$ ,则  $U^{(i)}$  便可作为所求的近似最优解.其中: $\delta > 0$  为允许误差, $U^{(i)}$  为当前迭代环节的预测控制输入序列, $\mu^{(i)}$  为当前迭代环节的步长, $f^{(i)}$  为搜索方向, $B^{(i)}$  为 Hessian 近似矩阵, $G(U^{(i)})$  为梯度向量,而

$$f^{(i)} = -B^{(i)} G(U^{(i)}),$$

(16)

$$G(U^{(i)}) = \left. \frac{\partial L(U(t))}{\partial U(t)} \right|_{U(t)=U^{(i)}(t)} = -2[R(t) - Y(t)] \frac{\partial Y(t)}{\partial U(t)} + 2\Delta U(t) \frac{\partial \Delta U(t)}{\partial U(t)} \Big|_{U(t)=U^{(i)}(t)}.$$

(17)

因为  $\Delta u(t) = u(t) - u(t-1)$ ,所以

$$\frac{\partial \Delta U(t)}{\partial U(t)} = \begin{bmatrix} \frac{\partial u(t)}{\partial u(t)} & \cdots & \frac{\partial \Delta u(t)}{\partial u(t+N_u)} \\ \cdots & \ddots & \cdots \\ \frac{\partial u(t+N_u)}{\partial u(t)} & \cdots & \frac{\partial \Delta u(t+N_u)}{\partial u(t+N_u)} \end{bmatrix} =$$

$$\begin{bmatrix} 1 & 0 & \cdots & 0 \\ -1 & 1 & \cdots & 0 \\ \cdots & \cdots & \ddots & \cdots \\ 0 & 0 & \cdots & 1 \end{bmatrix} \cdot \quad (18)$$

另外

$$\frac{\partial \hat{Y}(t)}{\partial U(t)} = \begin{bmatrix} \frac{\partial \hat{Y}(t+N_1)}{\partial u(t)} & \cdots & \frac{\partial \hat{Y}(t+N_1)}{\partial u(t+N_u-1)} \\ \cdots & \ddots & \cdots \\ \frac{\partial \hat{Y}(t+N_2)}{\partial u(t)} & \cdots & \frac{\partial \hat{Y}(t+N_2)}{\partial u(t)} \end{bmatrix} \cdot \quad (19)$$

由式(13)可知,对于所有  $k \in [N_1, N_2]$  和  $l \in [0, N_u - 1]$ , 矩阵(19)中的各项可通过下式求得:

$$\frac{\partial \hat{Y}(t+k)}{\partial u(t+l)} = \sum_i^k CA^{i-1}B \frac{\partial f(u_{t+k-i})}{\partial u(t+l)} + D \frac{\partial f(u_{t+k})}{\partial u(t+l)} = \begin{cases} CA^{k-l}B \exp\left(-\frac{\|u(t+l) - u_{sv}\|^2}{2\sigma^2}\right) \times \left(-\frac{u(t+l) - u_{sv}}{\sigma^2}\right), l = k - i; \\ D \exp\left(-\frac{\|u(t+l) - u_{sv}\|^2}{2\sigma^2}\right) \times \left(-\frac{u(t+l) - u_{sv}}{\sigma^2}\right), l = k. \end{cases} \quad (20)$$

下面给出拟牛顿算法的具体步骤:

- Step1: 给出预测控制输入的初始序列  $U^{(0)}$ , 计算性能指标  $J(U^{(0)})$  和梯度  $G(U^{(0)})$ , 初始化 Hessian 近似矩阵  $B^{(0)} = I, i = 0$ ;
- Step2: 确定搜索方向  $f^{(i)} = -B^{(i)}G(U^{(i)})$ ;
- Step3: 进行一维精确搜索确定步长  $\mu^{(i)}$ , 满足  $J(U^{(i)} + \mu^{(i)}f^{(i)}) = \min\{J(U^{(i)} + \mu f^{(i)}) \mid \mu \geq 0\}$ ;
- Step4: 更新预测控制输入序列  $U^{(i+1)} = U^{(i)} + \mu^{(i)}f^{(i)}$ ;
- Step5: 如果满足  $|U^{(i)} - U^{(i-1)}| < \delta$ , 则转入 Step7, 否则进入 Step5;
- Step6: 令  $q^{(i)} = G(U^{(i+1)}) - G(U^{(i)})$ , 更新 Hessian 近似矩阵  $B^{(i+1)} = B^{(i)} + \frac{\Delta U^{(i)} \Delta U^{(i)T}}{\Delta U^{(i)T} q^{(i)}} - \frac{B^{(i)} q^{(i)} q^{(i)T} B^{(i)}}{q^{(i)T} B^{(i)} q^{(i)}};$
- Step7:  $i = i + 1$ , 转入 Step1;
- Step8:  $U^{(i)}$  作为近似最优解, 算法终止.

5 仿真实验




图 3 水箱系统示意图

考虑图 3 所示的水箱液位控制系统. 水从上部流入水箱, 经下方的圆孔流出. 当流入量与流出量达到平衡时, 将在水箱内形成稳定的液位. 从物理特性上分析, 流入的水量与水泵的电压  $v$  成比例关系, 水从底部流出的速率正比于液位高度的平方根  $\sqrt{h}$ . 由出入的总水量守恒可得到液位高度与水泵电压之间的关系

$$Sdh/dt = bv - a\sqrt{h}. \quad (21)$$

其中:  $S$  代表水箱的横截面积,  $a$  和  $b$  为相应的比例系数. 由式(21)可以看出, 液位高度与水泵电压之间存在明显的非线性函数关系, 是一个典型的非线性液位控制问题.

以周期为 1 s 的时间间隔采样得到样本数为 200 的一组输入输出数据, 输入量为水泵电压  $v$ , 输出量为液位高度  $h$ . 取前 100 个数据作为训练集, 后 100 个数据作为验证集, 进行基于支持向量机的非线性 N4SID 模型辨识, 得到式(9)的非线性状态空




图 4 模型响应的验证曲线




图 5 仿真控制结果

间模型,其中: $A = [0.973 \ 62]$ ,  $B = [0.040 \ 53]$ ,  $C = [2.433 \ 7]$ ,  $D = [0.000 \ 12]$ . 模型响应与验证数据的匹配精度如图4所示.

利用辨识得到的状态空间模型构造式(13)的预测模型,建立非线性预测控制器,并用拟牛顿法求解非线性预测控制律,最终得到闭环仿真控制结果如图5所示.从图中可以看出,控制效果较为理想.

## 6 结 语

本文针对工业控制领域的非线性系统,运用最小二乘支持向量机函数估计理论进行非线性 N4SID 模型辨识,建立了基于支持向量机的非线性状态空间预测模型;在此基础上实现了一种非线性预测控制算法,并用拟牛顿法进行每一周期内的非线性优化求解;最后以非线性液位控制为例进行仿真研究,验证了这一非线性预测控制的有效性和可行性.

关于支持向量机与预测控制相结合的研究,这里只是作了初步尝试,而更多的工作还有待继续.例如:1)如何使算法的收敛速度加快;2)如何选择支持向量机的核函数;3)如何保证这类方法的稳定性和鲁棒性.深入研究这些问题,有望形成一套系统的基于支持向量机的非线性预测控制理论与方法.

## 参考文献(References)

- [1] Vapnik V N, Golowich S, Smola A. Support vectormethod for function approximation, regression estimation and signal processing [C]. Advances in Neural Information Processing Systems. Cambridge: MIT Press, 1996: 281-287.
- [2] Drucker H, Burges C J C, Kaufman L, et al. Support vector regression machines [C]. Advances in Neural Information Procession Systems. Cambridge: MIT Press, 1997: 155-161.
- [3] Vapnik V N. The nature of statistical learning theory [M]. 2nd ed. New York: Springer-Verlag, 1999.
- [4] 王宇红, 黄德先, 高东杰, 等. 基于 LS-SVM 的非线性预测控制技术[J]. 控制与决策, 2004, 19(4): 383-387.  
(Wang Y H, Huang D X, Gao D J, et al. Nonlinear predictive control based on LS-SVM[J]. Control and Decision, 2004, 19(4): 383-387.)
- [5] Suykens J A K, Vandewalle J, Moor B D. Optimal control by least squares support vector machines[J]. Neural Networks, 2001, 14(1): 23-35.
- [6] Suykens J K A, Vandewalle J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [7] Suykens J K A. Nonlinear modelling and support vector machines[C]. Proc of the IEEE-IMTC 2001 State-of-the-Art Lecture. Budapest, 2001: 287-294.
- [8] Goethals I, Pelckmans K, Suykens J K A, et al. Subspace identification of hammerstein systems using least squares support vector machines[J]. IEEE Trans on Automatic Control: Special Issue on System Identification, 2005, 50(10): 1509-1519.
- [9] Norgaard M, Ravn O, Poulsen N K, et al. Neural networks for modeling and control of dynamic systems [M]. New York: Springer, 2000.
- [10] Camacho E F, Bordons C. Model predictive control [M]. London: Springer, 1999.
- [7] 王欣荣, 樊治平. 一种基于语言评价信息的多指标群决策方法[J]. 系统工程学报, 2003, 18(2): 173-176  
(Wang X R, Fan Z P. Approach to multiple attribute group decision making with linguistic assessment information[J]. J of Systems Engineering, 2003, 18(2): 173-176.)
- [8] Xu Z S. Uncertain linguistic aggregation operators based approach to multiple attribute group decision making under uncertain linguistic environment[J]. Information Sciences, 2004, 168: 171-184.
- [9] Herrera F, Martínez L. A 2-tuple fuzzy linguistic representation model for computing with words[J]. IEEE Trans on Fuzzy Systems, 2000, 8(6): 746-752.
- [10] Delgado M, Herrera F. A communication model based on 2-tuple fuzzy linguistic representation for a distributed intelligent agent system on internet [J]. Soft Computing, 2002, 6(3): 320-328.
- [11] 王坚强. 基于离差优化的信息不完全确定的多准则分类方法[J]. 控制与决策, 2006, 21(5): 513-516.  
(Wang J Q. Multi-criteria classification approach with incomplete certain information base on optimizing deviation of categories[J]. Control and Decision, 2006, 21(5): 513-516)
- [12] Yang J B, Singh M G. An evidential reasoning approach for multiple attribute decision making with uncertainty[J]. IEEE Trans on Systems, Man and Cybernetics, 1994, 24(1): 1-18.

(上接第548页)